

UNIVERSIDAD AUTONOMA DE MADRID

ESCUELA POLITECNICA SUPERIOR



PROYECTO FIN DE MÁSTER

**DISEÑO Y OPTIMIZACIÓN DE DISPOSITIVOS DE
MICROONDAS MEDIANTE MODELOS NUMÉRICOS
APROXIMADOS**

Pablo Pascual García

JULIO 2014

DISEÑO Y OPTIMIZACIÓN DE DISPOSITIVOS DE MICROONDAS MEDIANTE MODELOS NUMÉRICOS APROXIMADOS

AUTOR: Pablo Pascual García

TUTOR: Jorge A. Ruiz Cruz

Grupo de Radiofrecuencia: Circuitos, Antenas y Sistemas.



Dpto. de Tecnología Electrónica y de las Comunicaciones

Escuela Politécnica Superior

Universidad Autónoma de Madrid

Julio de 2014

Resumen

Actualmente, para diseñar componentes de microondas se usa principalmente simuladores electromagnéticos como HFSS o CST. Para determinadas estructuras, el tiempo de simulación puede ser muy lento por lo que llevar a cabo una optimización para alcanzar la respuesta objetivo supone muchas horas de simulación. El objetivo de este proyecto es buscar alternativas que permitan reducir dicho tiempo. Para ello se van a utilizar redes neuronales y técnicas de mapeado espacial.

La primera parte del proyecto se centra en el uso de redes neuronales, las cuales son capaces de aprender mediante entrenamiento relaciones no lineales entre las entradas y las salidas. Se probará su utilidad en el diseño de filtro en guía de onda que utilizan iris y en acopladores híbridos. Para el entrenamiento y la simulación de las redes se aprovechará el *toolbox* que ofrece *Matlab*.

La segunda parte del proyecto se centrará en las técnicas de mapeado espacial, las cuales se aplicarán en filtros en guía y filtros de cavidades. Con el mapeado espacial se pretende reducir el número de simulaciones en HFSS o CST debido a su excesivo tiempo de simulación. Se utilizan adicionalmente otros modelos de la estructura cuyas simulaciones son menos costosas.

Palabras clave

Parámetros S, microondas, optimización, redes neuronales artificiales, entrenamiento, perceptrón multicapa, épocas, guía de onda, diseño de acopladores, diseño de filtros, simulación electromagnética, mapeado espacial, actualización de *Broyden*, modelo grueso, modelo fino, extracción de parámetros, matriz de acoplo, iris, cavidad resonante, reflexión, transmisión, aislamiento.

Abstract

At present, electromagnetic simulators such as HFSS or CST are used for designing microwave components. Some structures are very time consuming in order to finish a simulation so many hours are needed to complete an optimization. The goal of this project is to find techniques which reduce simulation time. The techniques used in this work are artificial neural networks and space mapping.

Firstly, artificial neural networks are used. These can be trained to learn nonlinear input-output relationships. Waveguide iris filters and hybrid couplers are the structures used to try to reduce simulation time with the proposed approach. Matlab toolbox is used for training and simulation.

Space mapping techniques are used with waveguide and cavity filters. In this case, the number of simulations in HFSS or CST is reduced thanks to the use of two models of the structure.

Key words

S-parameters, microwave, optimization, artificial neural networks, training, multilayer perceptron, epochs, waveguide, coupler design, filter design, electromagnetic simulation, space mapping, Broyden update, coarse model, fine model, parameter extraction, coupling matrix, iris, resonant cavity, reflection, transmission, isolation.

Agradecimientos

En primer lugar a mi tutor, Jorge, por darme la posibilidad de realizar este trabajo con él, por su dedicación, por las horas que hemos pasado, por lo que he aprendido de él y por sus consejos. Gracias por confiar en mí.

En segundo lugar a todos los profesores del RFCAS que siempre han estado ahí y me han ayudado en todo lo que han podido.

Gracias a todos los miembros del RFCAS, por las horas compartidas y el tiempo pasado juntos. Especial mención a Pablo, compañero en la empresa, en el laboratorio y ahora también en el despacho. Muchas gracias por estar siempre dispuesto a echarme una mano.

Gracias a los compañeros del máster, que han hecho que las horas de clase fueran más llevaderas.

Gracias a mis amigos y familia por estar ahí, por los buenos y los malos ratos, por aguantarme y darme ánimos en los malos momentos.

Índice

1	INTRODUCCIÓN.....	1
1.1	MOTIVACIÓN	1
1.2	OBJETIVOS	2
1.3	ORGANIZACIÓN DE LA MEMORIA	2
2	DISEÑO DE FILTROS EN GUÍA DE ONDA A TRAVÉS DE REDES NEURONALES	3
2.1	FUNDAMENTOS TEÓRICOS DE LAS REDES NEURONALES.....	3
2.1.1	<i>Introducción a las redes neuronales.....</i>	<i>3</i>
2.1.2	<i>Estructura de una red neuronal</i>	<i>3</i>
2.1.3	<i>Desarrollo del modelo de la red neuronal</i>	<i>6</i>
2.1.4	<i>Ventajas e inconvenientes de las redes neuronales</i>	<i>8</i>
2.1.5	<i>Redes neuronales en Matlab: Neural Network Toolbox.....</i>	<i>9</i>
2.2	INTRODUCCIÓN	10
2.3	OBTENCIÓN DE LOS DATOS DE ENTRENAMIENTO	12
2.4	SIMULACIÓN DE FILTRO COMPLETO	13
2.4.1	<i>Red neuronal 1 – Filtro completo y red independiente de la frecuencia</i>	<i>14</i>
2.4.2	<i>Red neuronal 2 – Filtro completo y red dependiente de la frecuencia</i>	<i>16</i>
2.4.3	<i>Conclusiones.....</i>	<i>17</i>
2.5	CARACTERIZACIÓN DE IRIS	17
2.5.1	<i>Red neuronal 1.....</i>	<i>18</i>
2.5.2	<i>Red neuronal 2.....</i>	<i>20</i>
2.5.3	<i>Red neuronal 3.....</i>	<i>23</i>
2.5.4	<i>Red neuronal 4.....</i>	<i>27</i>
2.5.5	<i>Red neuronal 5.....</i>	<i>29</i>
2.5.6	<i>Conclusiones.....</i>	<i>33</i>
3	DISEÑO DE ACOPLADORES	35
3.1	FUNDAMENTOS TEÓRICOS DE LOS ACOPLADORES.....	35
3.2	DISEÑO DE UN ACOPLADOR HÍBRIDO DE 2 RAMAS.....	38
3.3	DISEÑO DE UN ACOPLADOR HÍBRIDO ORDEN 2 – 3 RAMAS	41
3.4	DISEÑO DE UN ACOPLADOR HÍBRIDO ORDEN 3 – 4 RAMAS	42
4	DISEÑO DE ACOPLADORES EN GUÍA DE ONDA A TRAVÉS DE REDES NEURONALES.....	45
4.1	INTRODUCCIÓN	45
4.2	CARACTERIZACIÓN DE UN ACOPLADOR DE ORDEN 2	45
4.3	RED DEPENDIENTE DE LA FRECUENCIA.....	53
5	DISEÑO DE FILTROS MEDIANTE MAPEADO ESPACIAL.....	57
5.1	FUNDAMENTOS TEÓRICOS DEL SPACE MAPPING	57
5.2	ESQUEMA DE FUNCIONAMIENTO.....	59
5.2.1	<i>Asociación de parámetros mediante curvas de caracterización</i>	<i>60</i>
5.2.2	<i>Conversión del modelo grueso al modelo fino.....</i>	<i>62</i>
5.2.3	<i>Conversión del modelo fino al grueso</i>	<i>63</i>
5.2.4	<i>Reoptimización del modelo grueso</i>	<i>63</i>
5.3	FUNCIONAMIENTO	64
5.4	EJEMPLO 1: OPTIMIZACIÓN DE FILTRO DE IRIS DE ORDEN 5	64

5.4.1	<i>Filtro objetivo</i>	64
5.4.2	<i>Diseño HFSS</i>	65
5.4.3	<i>Obtención de las curvas de caracterización</i>	67
5.4.4	<i>Asociación de parámetros</i>	70
5.4.5	<i>Optimización</i>	71
5.5	EJEMPLO 2: OPTIMIZACIÓN DE FILTRO DE CAVIDADES DE ORDEN 5.....	78
5.5.1	<i>Filtro objetivo</i>	78
5.5.2	<i>Diseño HFSS</i>	78
5.5.3	<i>Obtención de las curvas de caracterización</i>	81
5.5.4	<i>Asociación de parámetros</i>	85
5.5.5	<i>Optimización</i>	86
5.6	CONCLUSIONES	90
6	CONCLUSIONES Y TRABAJO FUTURO	91
6.1	CONCLUSIONES	91
6.2	TRABAJO FUTURO	92

Índice de figuras

FIG. 2-1: ESTRUCTURA DE UNA RED NEURONAL MULTICAPA.	4
FIG. 2-2: FUNCIÓN SIGMOIDEA.	5
FIG. 2-3: ENTRENAMIENTO DE UNA RED NEURONAL CON <i>MATLAB</i>	10
FIG. 2-4: ESTRUCTURA FILTRO ORDEN 3.	11
FIG. 2-5: RESPUESTA FILTRO ORDEN 3.	11
FIG. 2-6: ESTRUCTURA DE LA RED NEURONAL.	12
FIG. 2-7: ESTRUCTURA DE LA RED NEURONAL SIMPLIFICADA.	12
FIG. 2-8: ESTRUCTURA UTILIZADA PARA LA CARACTERIZACIÓN DEL IRIS.	13
FIG. 2-9: ESTRUCTURA DEL FILTRO COMPLETO QUE SE REPRODUCE CON REDES NEURONALES.	13
FIG. 2-10: ESTRUCTURA DE LA RED NEURONAL DEL DISEÑO 1.	14
FIG. 2-11: ENTRENAMIENTO DE UNA RED NEURONAL CON <i>MATLAB</i>	14
FIG. 2-12: COMPARACIÓN DE LA TRANSMISIÓN DEL DISEÑO 1.	15
FIG. 2-13: COMPARACIÓN DE LA REFLEXIÓN DEL DISEÑO 1.	15
FIG. 2-14: ESTRUCTURA DE LA RED NEURONAL DEL DISEÑO 2.	16
FIG. 2-15: COMPARACIÓN DE LA TRANSMISIÓN PARA EL DISEÑO 2.	16
FIG. 2-16: COMPARACIÓN DE LA REFLEXIÓN PARA EL DISEÑO 2.	17
FIG. 2-17: IRIS CARACTERIZADO A TRAVÉS DE REDES NEURONALES.	18
FIG. 2-18 ESTRUCTURA DE LAS REDES NEURONALES PARA LA CARACTERIZACIÓN DE UN IRIS (DISEÑO 1).	18
FIG. 2-19: COMPARACIÓN DE LA TRANSMISIÓN PARA EL DISEÑO 1.	19
FIG. 2-20: COMPARACIÓN DE LA REFLEXIÓN PARA EL DISEÑO 1.	19
FIG. 2-21: ESTRUCTURA DE LAS REDES NEURONALES PARA LA CARACTERIZACIÓN DE UN IRIS (DISEÑO 2).	20
FIG. 2-22: COMPARACIÓN DE LA TRANSMISIÓN PARA EL DISEÑO 2.	21
FIG. 2-23: COMPARACIÓN DE LA REFLEXIÓN PARA EL DISEÑO 2.	21
FIG. 2-24: CARACTERIZACIÓN DE UN IRIS DE APERTURA 7.76 MM. MÓDULO Y FASE.	22
FIG. 2-25: CARACTERIZACIÓN DE UN IRIS DE APERTURA 6.375 MM. MÓDULO Y FASE.	23
FIG. 2-26: ESTRUCTURA DE LAS REDES NEURONALES PARA LA CARACTERIZACIÓN DE UN IRIS (DISEÑO 3).	23
FIG. 2-27 COMPARACIÓN DE LA TRANSMISIÓN PARA EL DISEÑO 3.	24
FIG. 2-28: COMPARACIÓN DE LA REFLEXIÓN PARA EL DISEÑO 3.	25
FIG. 2-29: CARACTERIZACIÓN DE UN IRIS DE APERTURA 7.76 MM. MÓDULO Y FASE.	26
FIG. 2-30: CARACTERIZACIÓN DE UN IRIS DE APERTURA 6.375 MM. MÓDULO Y FASE.	26
FIG. 2-31: ESTRUCTURA DE LA RED NEURONAL PARA LA CARACTERIZACIÓN DE UN IRIS (DISEÑO 4).	27
FIG. 2-32: COMPARACIÓN DE LA TRANSMISIÓN PARA EL DISEÑO 4.	27
FIG. 2-33: COMPARACIÓN DE LA REFLEXIÓN PARA EL DISEÑO 4.	28
FIG. 2-34: CARACTERIZACIÓN DE UN IRIS DE APERTURA 7.76 MM. MÓDULO Y FASE.	29
FIG. 2-35: CARACTERIZACIÓN DE UN IRIS DE APERTURA 6.375 MM. MÓDULO Y FASE.	29
FIG. 2-36: ESTRUCTURA DE LAS REDES NEURONALES PARA LA CARACTERIZACIÓN DE UN IRIS (DISEÑO 5).	30
FIG. 2-37: COMPARACIÓN DE LA TRANSMISIÓN PARA EL DISEÑO 5.	30
FIG. 2-38: COMPARACIÓN DE LA REFLEXIÓN PARA EL DISEÑO 5.	31
FIG. 2-39: CARACTERIZACIÓN DE UN IRIS DE APERTURA 7.76 MM. MÓDULO Y FASE.	32
FIG. 2-40: CARACTERIZACIÓN DE UN IRIS DE APERTURA 6.375 MM. MÓDULO Y FASE.	32
FIG. 3-1: SÍMBOLO ACOPLADORES DIRECCIONALES.	35
FIG. 3-2: MULTIHOLE COUPLER.	37
FIG. 3-3: MORENO CROSSED-GUIDE COUPLER (DE [1]).	38
FIG. 3-4: ACOPLADOR HÍBRIDO <i>BRANCH GUIDE</i> ORDEN 1.	39
FIG. 3-5: ESQUEMA DEL ACOPLADOR HÍBRIDO <i>BRANCH GUIDE</i> ORDEN 1.	39

FIG. 3-6: RESPUESTA DEL ACOPLADOR DE ORDEN 1 (MÓDULO)	40
FIG. 3-7: RESPUESTA DEL ACOPLADOR DE ORDEN 1 (FASE).....	40
FIG. 3-8: ACOPLADOR HÍBRIDO <i>BRANCH GUIDE</i> ORDEN 2.	41
FIG. 3-9: ESQUEMA DEL ACOPLADOR HÍBRIDO <i>BRANCH GUIDE</i> ORDEN 2.	41
FIG. 3-10: RESPUESTA DEL ACOPLADOR DE ORDEN 2 (MÓDULO).	42
FIG. 3-11: RESPUESTA DEL ACOPLADOR DE ORDEN 2 (FASE).....	42
FIG. 3-12: ACOPLADOR HÍBRIDO <i>BRANCH GUIDE</i> ORDEN 3.	43
FIG. 3-13: ESQUEMA DEL ACOPLADOR HÍBRIDO <i>BRANCH GUIDE</i> ORDEN 3.	43
FIG. 3-14: RESPUESTA DEL ACOPLADOR DE ORDEN 3 (MÓDULO).	44
FIG. 3-15: RESPUESTA DEL ACOPLADOR DE ORDEN 3 (FASE).....	44
FIG. 4-1: ESTRUCTURA DEL ACOPLADOR DE ORDEN 2.	45
FIG. 4-2: ESTRUCTURA DE LA RED NEURONAL.	46
FIG. 4-3: RESPUESTA DEL ACOPLADOR OBJETIVO.	46
FIG. 4-4: RESPUESTA S_{11} DE LA RED ENTRENADA (1001 PUNTOS).	47
FIG. 4-5: RESPUESTA S_{21} DE LA RED ENTRENADA (1001 PUNTOS).....	47
FIG. 4-6: RESPUESTA S_{31} DE LA RED ENTRENADA (1001 PUNTOS).....	48
FIG. 4-7: RESPUESTA S_{41} DE LA RED ENTRENADA (1001 PUNTOS).....	48
FIG. 4-8: RESPUESTA S_{11} DE LA RED ENTRENADA (101 PUNTOS).	49
FIG. 4-9: RESPUESTA S_{21} DE LA RED ENTRENADA (101 PUNTOS).	49
FIG. 4-10: RESPUESTA S_{31} DE LA RED ENTRENADA (101 PUNTOS).	50
FIG. 4-11: RESPUESTA S_{41} DE LA RED ENTRENADA (101 PUNTOS).	50
FIG. 4-12: RESPUESTA S_{11} DE LA RED ENTRENADA (14 PUNTOS).	51
FIG. 4-13: RESPUESTA S_{21} DE LA RED ENTRENADA (14 PUNTOS).	51
FIG. 4-14: RESPUESTA S_{31} DE LA RED ENTRENADA (14 PUNTOS).	52
FIG. 4-15: RESPUESTA S_{41} DE LA RED ENTRENADA (14 PUNTOS).	52
FIG. 4-16: ESTRUCTURA DE LA RED NEURONAL DEPENDIENTE DE LA FRECUENCIA.	53
FIG. 4-17: RESPUESTA S_{11} DE LA RED ENTRENADA.	53
FIG. 4-18: RESPUESTA S_{21} DE LA RED ENTRENADA.	54
FIG. 4-19: RESPUESTA S_{31} DE LA RED ENTRENADA.	54
FIG. 4-20: RESPUESTA S_{41} DE LA RED ENTRENADA.	55
FIG. 5-1: MODELO FINO Y GRUESO EN EL MAPEADO ESPACIAL (DE [7])......	58
FIG. 5-2: RELACIÓN ENTRE EL MODELO FINO Y EL GRUESO DE ([7])......	59
FIG. 5-3: ESQUEMA DE FUNCIONAMIENTO DEL MAPEADO ESPACIAL PROPUESTO.....	59
FIG. 5-4: ASOCIACIÓN DE PARÁMETROS ENTRE EL MODELO FINO Y GRUESO.	60
FIG. 5-5: CURVA DE ACOPLO INTERNO.	61
FIG. 5-6: CONVERSIÓN DEL MODELO GRUESO AL FINO. FRECUENCIAS DE RESONANCIA.	62
FIG. 5-7: CONVERSIÓN DEL MODELO GRUESO AL FINO. ACOPLOS DIRECTOS.....	62
FIG. 5-8: FILTRO OBJETIVO PARA EL MAPEADO ESPACIAL.	65
FIG. 5-9: FILTRO DE IRISES A OPTIMIZAR EN HFSS.	66
FIG. 5-10: VARIABLES DEL FILTRO DE IRISES A OPTIMIZAR.	66
FIG. 5-11: RESPUESTA INICIAL DEL FILTRO.	67
FIG. 5-12: CURVA DE CARACTERIZACIÓN DE LA FRECUENCIA DE RESONANCIA 1	68
FIG. 5-13: CURVA DE CARACTERIZACIÓN DE LA FRECUENCIA DE RESONANCIA 2	68
FIG. 5-14: CURVA DE CARACTERIZACIÓN DE LA FRECUENCIA DE RESONANCIA 3	68
FIG. 5-15: ESTRUCTURA PARA OBTENER EL ACOPLO ENTRE CAVIDADES.....	69
FIG. 5-16: CURVA DE ACOPLO ENTRE CAVIDADES	69
FIG. 5-17: ESTRUCTURA PARA OBTENER EL ACOPLO DE ENTRADA.....	70
FIG. 5-18: CURVA DE ACOPLO PARA LA CAVIDAD DE ENTRADA	70
FIG. 5-19: ASOCIACIÓN DE PARÁMETROS ENTRE EL MODELO FINO Y EL MODELO GRUESO.....	71
FIG. 5-20: RESPUESTA DE PARÁMETROS S DE LA PRIMERA EXTRACCIÓN Y DEL FILTRO OBJETIVO.	72

FIG. 5-21: RESPUESTA DE PARÁMETROS S DE LA SEGUNDA EXTRACCIÓN Y DEL FILTRO OBJETIVO.	73
FIG. 5-22: RESPUESTA DE PARÁMETROS S DE LA TERCERA EXTRACCIÓN Y DEL FILTRO OBJETIVO.....	74
FIG. 5-23: RESPUESTA DE PARÁMETROS S DE LA CUARTA EXTRACCIÓN Y DEL FILTRO OBJETIVO.	74
FIG. 5-24: RESPUESTA DE PARÁMETROS S DE LA QUINTA EXTRACCIÓN Y DEL FILTRO OBJETIVO.....	75
FIG. 5-25: RESPUESTA DE PARÁMETROS S DE LA SEXTA EXTRACCIÓN Y DEL FILTRO OBJETIVO.	75
FIG. 5-26: RESPUESTA DE PARÁMETROS S DE LA SÉPTIMA EXTRACCIÓN Y DEL FILTRO OBJETIVO.....	76
FIG. 5-27: RESPUESTA DE PARÁMETROS S DE LA ÚLTIMA EXTRACCIÓN Y DEL FILTRO OBJETIVO.....	76
FIG. 5-28: RESPUESTA OBJETIVO PARA EL FILTRO DE CAVIDADES.	78
FIG. 5-29: ESTRUCTURA DEL FILTRO DE CAVIDADES EN HFSS.	79
FIG. 5-30: PARTES METÁLICAS DE LA ESTRUCTURA.	79
FIG. 5-31: PARTES DE TEFLÓN EN LA ESTRUCTURA (I).	80
FIG. 5-32: PARTES DE TEFLÓN EN LA ESTRUCTURA (II).	80
FIG. 5-33: RESPUESTA INICIAL DEL FILTRO DE CAVIDADES.	81
FIG. 5-34: UBICACIÓN DEL TORNILLO DE AJUSTE EN LA CAVIDAD.....	82
FIG. 5-35: CURVA DE CARACTERIZACIÓN DEL PRIMER RESONADOR.	82
FIG. 5-36: CURVA DE CARACTERIZACIÓN DEL SEGUNDO RESONADOR.	83
FIG. 5-37: CURVA DE CARACTERIZACIÓN DEL TERCER RESONADOR.	83
FIG. 5-38: UBICACIÓN DE LA ALTURA DE LA VENTANA.....	83
FIG. 5-39: CURVA DE CARACTERIZACIÓN DEL ACOPLO ENTRE CAVIDADES.	84
FIG. 5-40: ESTRUCTURA PARA LA CARACTERIZACIÓN DEL ACOPLO DE ENTRADA.	84
FIG. 5-41: CURVA DE CARACTERIZACIÓN DEL ACOPLO DE ENTRADA.	85
FIG. 5-42: RESPUESTA INICIAL EXTRAÍDA.	86
FIG. 5-43: RESPUESTA DE PARÁMETROS S DE LA PRIMERA ITERACIÓN Y DEL FILTRO OBJETIVO.....	87
FIG. 5-44: RESPUESTA DE PARÁMETROS S DE LA ITERACIÓN 2 Y DEL FILTRO OBJETIVO.	87
FIG. 5-45: RESPUESTA DE PARÁMETROS S DE LA ITERACIÓN 3 Y DEL FILTRO OBJETIVO.	88
FIG. 5-46: RESPUESTA DE PARÁMETROS S DE LA ITERACIÓN 4 Y DEL FILTRO OBJETIVO.	88
FIG. 5-47: RESPUESTA DE PARÁMETROS S DE LA ITERACIÓN 5 Y DEL FILTRO OBJETIVO.	89
FIG. 5-48: RESPUESTA DE PARÁMETROS S DE LA ITERACIÓN 6 Y DEL FILTRO OBJETIVO.	89
FIG. 5-49: RESPUESTA DE PARÁMETROS S DE LA ITERACIÓN 7 Y DEL FILTRO OBJETIVO.	90

Índice de tablas

TABLA 2-1: FUNCIONES DE ACTIVACIÓN.....	5
TABLA 2-2: DIMENSIONES FILTRO ORDEN 3.	11
TABLA 3-1: DIMENSIONES DEL ACOPLADOR DE ORDEN 1.....	39
TABLA 3-2: DIMENSIONES DEL ACOPLADOR DE ORDEN 2.....	41
TABLA 3-3: DIMENSIONES DEL ACOPLADOR DE ORDEN 3.....	43
TABLA 4-1: DATOS DEL ACOPLADOR OBJETIVO.....	46
TABLA 5-1: MATRIZ DE ACOPLADO OBJETIVO.....	65
TABLA 5-2: MATRIZ DE ACOPLADO EXTRAÍDA PARA LA PRIMERA ITERACIÓN.	71
TABLA 5-3: MATRIZ DE ACOPLADO OBJETIVA.	72
TABLA 5-4: MATRIZ DE ACOPLADO EN LA ÚLTIMA ITERACIÓN.	77
TABLA 5-5: MATRIZ M OBJETIVO.....	77
TABLA 5-6: ASOCIACIÓN DE PARÁMETROS ENTRE EL MODELO FINO Y EL GRUESO.	85

1 Introducción

1.1 Motivación

El término microondas hace referencia a las señales cuya frecuencia está comprendida entre 300 MHz y 300 GHz, es decir, a las señales cuya longitud de onda está en el rango de 1 m a 1 mm. Debido a las altas frecuencias y, en consecuencia, bajas longitudes de onda, la teoría clásica de circuitos no puede utilizarse para resolver problemas de redes de microondas. Así, será necesario utilizar las ecuaciones de Maxwell para caracterizar el comportamiento de los dispositivos que operan en estas frecuencias. La naturaleza de estas ecuaciones hace que la complejidad matemática sea mayor pues involucran operaciones diferenciales e integrales con vectores de campo que dependen de coordenadas espaciales.

Las microondas están muy presentes en la actualidad: localización de objetivos, control de misiles, control de tráfico, detectores de movimiento, medida de distancias, predicción meteorológica, comunicaciones móviles, comunicaciones por satélite...

Además, el auge de los sistemas de comunicación por satélite, móvil o cable ha llevado a desarrollar nuevos sistemas de transmisión y recepción con prestaciones cada vez más sofisticadas. Estos utilizan principalmente la banda de frecuencia de las microondas.

Dentro de los circuitos de microondas, las estructuras en guía de onda son estructuras utilizadas habitualmente para construir filtros, acopladores, multiplexores, polarizadores... que adaptan la señal y la preparan para su posterior utilización en sistemas de telecomunicación (telefonía, televisión por satélite...).

La gran ventaja de las guías de onda es que son capaces de transmitir señales con mejores prestaciones eléctricas y mecánicas que las líneas de transmisión planares, a costa de un coste mayor. Son, por tanto, más robustas en ambientes adversos y proporcionan mayor fiabilidad. Esto hace que sean ampliamente usadas en comunicaciones por satélite donde las exigencias de los distintos componentes son muy elevadas.

Los dispositivos que se utilizan en esta banda son estructuras formadas por materiales conductores y dieléctricos cuya caracterización electromagnética, en función de su forma tridimensional, resulta fundamental para lograr diseños exitosos.

En la actualidad, el tiempo utilizado en las simulaciones electromagnéticas es muy elevado puesto que se realizan operaciones costosas y complejas. Si además se llevan a cabo optimizaciones para lograr cumplir las especificaciones, el tiempo necesario crece significativamente.

La motivación de este trabajo es buscar soluciones que permitan llevar a cabo simulaciones, y por consiguiente optimizaciones, en un tiempo mucho menor, objetivo que ahora está muy presente en la industria.

1.2 Objetivos

El objetivo de este proyecto es la búsqueda e implementación de algoritmos capaces de reducir el tiempo de simulación electromagnético de diferentes dispositivos en guía de onda (filtros y acopladores). Se va a utilizar para ellos dos técnicas: redes neuronales y mapeado espacial.

Con las redes neuronales se pretende que éstas sean capaces de aprender, tras un proceso de entrenamiento, la relación entre determinados parámetros físicos de la estructura y su respuesta de parámetros S.

Las técnicas de mapeado espacial, en cambio, se basan en utilizar dos modelos del sistema físico, siendo uno más costoso computacionalmente que el otro. Así, se busca conseguir información adicional sobre el modelo fino de manera que ayude a la búsqueda de la solución óptima. Esto supone la existencia de un mapeado entre los parámetros de los dos modelos. Utilizando técnicas de mapeado espacial se reduce el número de simulaciones costosas.

Se pretende probar estas soluciones para filtros de iris en guía de onda, filtros de cavidades y acopladores híbridos en guía.

1.3 Organización de la memoria

La memoria está dividida en seis capítulos:

- El primer capítulo incluye la motivación, objetivos y organización de la memoria.
- El segundo capítulo comienza con los fundamentos teóricos de las redes neuronales así como una introducción a la utilización del toolbox de Matlab, con las funciones más importantes. Posteriormente se presenta el uso de las redes neuronales para diseño de filtros en guía de onda, así como los resultados obtenidos.
- El tercer capítulo está dedicado a los acopladores. Se inicia con los fundamentos teóricos de los mismos y continua con el diseño de diferentes acopladores híbridos que serán posteriormente utilizados.
- El cuarto capítulo utiliza las redes neuronales para diseñar acopladores híbridos. Se muestran las redes neuronales utilizadas y los resultados obtenidos.
- El quinto capítulo presenta los fundamentos del mapeado espacial. Se muestra el tipo utilizado y el algoritmo desarrollado. A continuación aparecen los ejemplos con los que se ha probado y los resultados obtenidos.
- Por último, el capítulo seis muestra las conclusiones obtenidas durante la realización del proyecto, así como el trabajo futuro.

2 Diseño de filtros en guía de onda a través de redes neuronales

2.1 Fundamentos teóricos de las redes neuronales

2.1.1 Introducción a las redes neuronales

Las redes neuronales, también llamadas redes neuronales artificiales (ANN – Artificial Neural Networks), son sistemas de procesamiento de información que han sido diseñados basándose en la capacidad que tiene el cerebro humano de aprender de las observaciones y de generalizar por abstracción [4]. Las redes neuronales se caracterizan por:

- El procesamiento de la información tiene lugar en muchos elementos simples llamados neuronas.
- Las señales se pasan entre neuronas a través de enlaces de conexión.
- Cada enlace de conexión tiene un peso asociado.
- Cada red neuronal aplica una función de activación (típicamente no lineal) a su aporte neto para determinar su señal de salida.

Las redes neuronales son aplicadas en numerosas áreas como reconocimiento de patrones, procesamiento de habla, ingeniería biomédica... Esto es debido a su capacidad de ser entrenadas para aprender relaciones no lineales de entrada-salida.

2.1.2 Estructura de una red neuronal

2.1.2.1 Componentes básicos

Una red neuronal está formada por dos componentes: *neuronas* y enlaces de conexión o *sinapsis*. Las neuronas son los elementos de procesamiento de la información. Cada enlace tiene asociado un peso.

Cada neurona recibe estímulos de otras neuronas que están conectadas a ella, procesa la información y produce una salida. Las neuronas que reciben estímulos de fuera de la red neuronal se llaman *neuronas de entrada* mientras que las neuronas cuyas salidas son usadas externamente son *neuronas de salida*. Las neuronas que reciben estímulos de otras neuronas y que sus salidas estimulan a otras neuronas de la red se llaman *neuronas ocultas*.

2.1.2.2 Modelo de red neuronal

En una red neuronal, n y m representan el número de entradas y salidas de la misma. Así, x será un vector de tamaño n que contienen las entradas de la red e y un vector de tamaño m que contiene las salidas. Existe además el vector w que contiene los pesos asociados a los

diferentes enlaces. Existirán por tanto diferentes modelos de red neuronal en función de cómo se define w y de la manera en la que se calcula y a través de x y w .

2.1.2.3 MLP Neural Network: Multilayer Perceptron

a) Estructura y notación

La red neuronal *perceptrón multicapa* (*multilayer perceptron*, MLP) es una estructura muy usada [5]. En ella las neuronas se agrupan en capas. La primera es la capa de entrada y la última la de salida. El resto son *capas ocultas*.

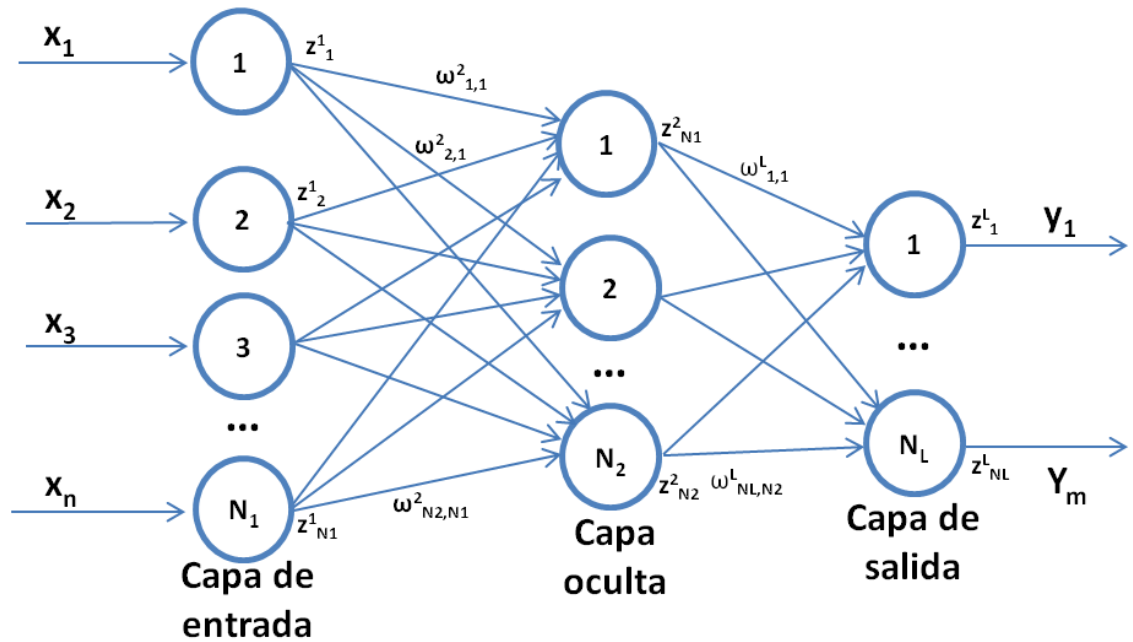


Fig. 2-1: Estructura de una red neuronal multicapa.

Una red neuronal MLP con una capa de entrada, una oculta y una de salida se conoce como MLP de 3 capas (*MLP3*).

w^l_{ij} representa el peso del enlace entre la neurona j de la capa $l-1$ y la neurona i de la capa l .

x_i representa la entrada externa a la red neuronal y z_i^l la salida de la neurona i de la capa l .

La matriz de pesos w de la red neuronal está compuesta por los diferentes valores de w^l_{ij} donde $j = 0, 1, \dots, N_{l-1}$, $i = 1, 2, \dots, N_l$ y $l = 2, 3, \dots, L$. Todos estos valores son números reales. Durante el entrenamiento de la red, estos valores cambian hasta que el entrenamiento finaliza y los valores quedan fijos de manera que permiten usar la red neuronal como modelo.

b) Anatomía de las neuronas

En la redes MLP cada neurona procesa el estímulo que le llega de las demás neuronas mediante una función de activación. La información procesada pasa a la salida de la neurona. Cada neurona de la capa l recibe estímulos de todas las neuronas de la capa $l-1$ ($z_1^{l-1}, z_2^{l-1}, \dots, z_{N_{l-1}}^{l-1}$) y procesa la información en dos pasos:

1. Cada una de las entradas es multiplicada por su correspondiente peso y posteriormente todos estos productos son sumados, tal y como se muestra a continuación:

$$\gamma_i^l = \sum_{j=0}^{N_{l-1}} w_{ij}^l z_j^{l-1} \quad (2.1)$$

2. El valor de γ_i^l obtenido en la ecuación anterior se utiliza para la función de activación de la neurona, produciendo así el valor de salida de la neurona, $z_i^l = \sigma(\gamma_i^l)$ el cual servirá de estímulo a las neuronas de la capa siguiente ($l+1$).

La función de activación más utilizada es la sigmoidea, la cual viene dada por la siguiente expresión:

$$\sigma(\gamma) = \frac{1}{(1 + e^{-\gamma})} \quad (2.2)$$




Fig. 2-2: Función sigmoidea.

Otras funciones de activación son:

Nombre	Relación entrada/salida
Lineal	$\sigma = \gamma$
Limitador fuerte	$\sigma = \begin{cases} 0 & \gamma < 0 \\ 1 & \gamma \geq 0 \end{cases}$
Limitador fuerte simétrico	$\sigma = \begin{cases} -1 & \gamma < 0 \\ 1 & \gamma \geq 0 \end{cases}$
Tangente sigmoideal	$\sigma = \frac{e^n - e^{-n}}{e^n + e^{-n}}$

Tabla 2-1: Funciones de activación.

c) Cálculo de las salidas (*Feedforward computation* o prealimentación):

Dado el vector de entrada x y el vector de pesos w se calcula el valor del vector de salida y . Al alimentar las neuronas de la capa de entrada, éstas generan unas salidas que alimentan a las neuronas de la primera capa oculta, éstas a las de la segunda y así hasta la capa $L-1$, la cual alimenta a las de la capa de salida.

$$\begin{aligned} z_i^1 &= x_i \quad i = 1, 2, \dots, N_1 \\ z_i^l &= \sigma \left(\sum_{j=0}^{N_{l-1}} w_{ij}^l z_j^{l-1} \right) \quad \begin{matrix} i = 1, 2, \dots, N_l \\ l = 2, 3, \dots, L \end{matrix} \\ y_i &= z_i^L \quad i = 1, 2, \dots, N_L \end{aligned} \tag{2.3}$$

El hecho de utilizar redes neuronales para simulación de componentes de microondas supone una menor complejidad en comparación uso de simuladores electromagnéticos que se encargan de resolver ecuaciones electromagnéticas.

Según el teorema de aproximación universal, siempre existe una red neuronal MLP de tres capas capaz de aproximar a cualquier función continua, no lineal y multidimensional.

2.1.3 Desarrollo del modelo de la red neuronal

2.1.3.1 Formulación del problema y procesamiento de datos

i. Entradas y salidas de la red:

El primer paso para la desarrollar una red neuronal es la identificación de las entradas (x) y salidas (y). Los parámetros de salida se determinan en función del propósito de la red neuronal. Así, para modelar componentes pasivos de RF se puede utilizar por ejemplo la parte real e imaginaria de los parámetros S .

A la hora de elegir estos hay que tener en cuenta también la facilidad para generar los datos.

En cuanto a los datos de entrada, estos modelarán parámetros físicos del circuito, geométricos, frecuencia... que afectan a la salida.

ii. Generación de los datos

En este paso se generan pares de muestras x - y mediante simulación software (ej. simulación electromagnética a través de CST o HFSS) o medida de dispositivos (ej. medida de parámetros S a través de un analizador de redes). Donde x e y corresponden a un vector.

Los datos generados pueden usarse tanto para entrenar la red neuronal como para validar el modelo obtenido.

En la práctica, tanto las medidas como las simulaciones pueden tener errores pequeños debido a la no convergencia del simulador (CST, HFSS...), truncamiento, tolerancias... Teniendo en cuenta esto se introduce el vector d que representa las salidas obtenidas mediante simulación o medida correspondientes a la entrada x .

Se genera entonces el par de muestras (x_k, d_k) donde $k = 1, 2, \dots, P$.

El número total de muestras P es elegido de manera que represente lo más fielmente posible el problema. Cuantas más dimensiones tenga el problema más muestras serán necesarias.

iii. Organización de los datos

Los pares de muestras generadas x, d se dividen en tres conjuntos:

- Datos de entrenamiento (T_r). Utilizados en el proceso de entrenamiento para actualizar el valor de la matriz de pesos.
- Datos de validación (V). Usado para monitorizar la calidad del modelo obtenido y como criterio de parada durante el proceso de entrenamiento.
- Datos de test (T_e). Utilizado para examinar la calidad final de la red neuronal en términos de precisión y capacidad de generalizar.

Idealmente estos tres conjuntos deben representar adecuadamente el comportamiento de la función a modelar $y = f(x)$. Si el número de muestras es suficientemente grande se puede realizar esta división. Si el número de muestras es limitado se puede dividir únicamente en dos conjuntos, usando uno para entrenamiento y validación ($T_r = V$) y el otro para test (T_e) o usando uno para entrenamiento (T_r) y otro para validación y test ($V = T_e$).

2.1.3.2 Training. El proceso de entrenamiento:

i. Inicialización de la matriz de pesos

En este paso se prepara la red neuronal para entrenarla. Para lograr un buen punto de partida para la optimización se inicializa la matriz de pesos, típicamente con valores aleatorios pequeños, entre -0.5 y 0.5.

ii. Formulación del proceso de entrenamiento

El proceso de entrenamiento es el punto más importante en el desarrollo de la red neuronal. Consiste en pares de muestras x_k y d_k , los cuales son vectores de tamaño m y n respectivamente, y que representan la entrada y su correspondiente salida. El error de entrenamiento de la red se define según la siguiente ecuación:

$$E_{Tr}(w) = \frac{1}{2} \cdot \sum_{k \in T_r} \sum_{j=1}^m |y_j(x_k, w) - d_{jk}|^2 \quad (2.4)$$

Donde d_{jk} es el elemento j del vector d_k e $y_j(x_k, w)$ es la salida j de la red para la entrada x_k .

El objetivo del entrenamiento será encontrar el valor de la matriz de pesos, w , que minimice el error de entrenamiento $E_{Tr}(w)$.

Puesto que $E_{Tr}(w)$ es una función no lineal se usan algoritmos iterativos para explorar el espacio de w . Se empieza por tanto con los valores iniciales de w y se van actualizando. Las técnicas de entrenamientos basadas en el gradiente llevan a cabo esta actualización en función del error de entrenamiento y su derivada.

Los algoritmos usados habitualmente para entrenar la red neuronal en aplicaciones de RF/microondas son los basados en gradiente, como el método quasi-Newton, gradiente conjugado, *backpropagation*... Los métodos globales de optimización como el *stimulated annealing* requieren un tiempo mayor de entrenamiento.

Existen dos maneras de minimizar el error de entrenamiento:

- On-Line: El aprendizaje se realiza patrón a patrón. Durante todo el entrenamiento se le pasa a la red cada entrada junto con su salida deseada, se mide el error y en función de éste se adapta la matriz de pesos.
- Batch: El aprendizaje se realiza época a época. Una época supone el paso de todos los patrones de entrenamiento por la red. De esta manera, se le pasa a la red todas las entradas junto con sus salidas, se calcula el error total cometido y se adapta la matriz de pesos en función de este valor.
-

2.1.4 Ventajas e inconvenientes de las redes neuronales

A continuación se enumeran una serie de ventajas de las redes neuronales:

- Una neurona es un elemento no lineal por lo que una interconexión de ellas también será un dispositivo no lineal. Esta propiedad permite la simulación de sistemas no lineales y caóticos.
- Son sistemas tolerantes a fallos. Una red neuronal, al ser un sistema distribuido, permite el fallo de algunos elementos individuales (neuronas) sin alterar significativamente la respuesta total del sistema.
- Adaptabilidad: Una red neuronal tiene la capacidad de modificar los parámetros de los que depende su funcionamiento de acuerdo con los cambios que se produzcan en sus entradas. La capacidad de adaptación tampoco puede ser excesivamente grande pues conduciría a tener un sistema inestable.

- Establecen relaciones no lineales entre datos. Las redes neuronales son capaces de relacionar dos conjuntos de datos.

Por el contrario, las redes neuronales ofrecen una serie de inconvenientes:

- Complejidad de aprendizaje para grandes tareas. Cuanto más se necesite que aprenda una red, más complicado será enseñarle.
- Tiempo de aprendizaje elevado.
- Es necesaria una cantidad elevada de datos para el entrenamiento. Será mayor cuantos más parámetros haya en la entrada.
- Criterios de dimensionamiento de la red neuronal arbitrarios.
- La inicialización aleatoria de los pesos y la división de los datos en entrenamiento, validación y test da lugar a soluciones diferentes.

2.1.5 Redes neuronales en *Matlab: Neural Network Toolbox*

Matlab cuenta con un *toolbox* de redes neuronales en el que se incluyen funciones ya predefinidas para simular diferentes tipos de modelos neuronales. Así, algunos de los parámetros que se pueden modificar son:

- Función utilizada para inicializar los valores de la matriz de pesos.
- Función de transferencia (lineal, tangente sigmoideal...).
- Función de entrenamiento (quasi-Newton, gradient, Levenber-Marquardt...).
- Número de épocas.
- Error de entrenamiento objetivo.
- Porcentaje de los datos de entrada usados para entrenamiento, validación y test.

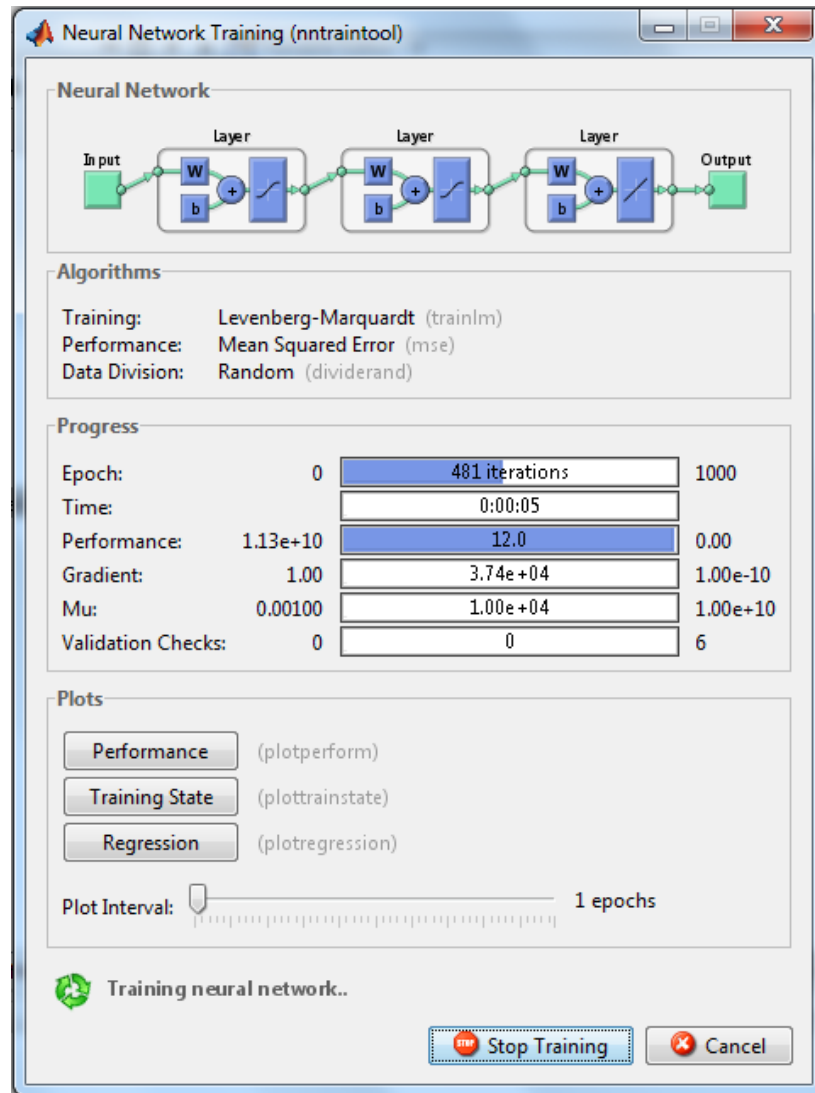
Principales funciones:

- ***newff(I, O, Layers)***: Esta función crea la estructura de la red neuronal. *I* es una matriz de *nxnum_muestras* y *O* de *mxnum_muestras*.

Layers define el número de capas ocultas así como las neuronas de cada capa oculta. Si *Layers* = [10 5] se definirán dos capas ocultas de 10 y 5 neuronas respectivamente.

- ***train(net, I, O)***: Función encargada de llevar a cabo el entrenamiento de la red neuronal.
- ***sim(net, I')***: La función *sim* se encarga de llevar a cabo la simulación de la red neuronal para un vector de entradas dado, *I'*. Utiliza la red que ha sido entrenada con la función anterior.

La figura siguiente muestra el proceso de entrenamiento de una red neuronal a través del *toolbox* de *Matlab*:

Fig. 2-3: Entrenamiento de una red neuronal con *Matlab*.

2.2 Introducción

En este capítulo se pretende entrenar una red neuronal para que sea capaz de reproducir el comportamiento de un filtro en guía de onda de orden 3, dados sus parámetros físicos. Gracias a esto, se podrá llevar a cabo la simulación del filtro con dimensiones arbitrarias en un tiempo menor que el que se necesita utilizando *CST Microwave Studio* o cualquier otro simulador electromagnético. El objetivo final es utilizar esta red para llevar a cabo optimizaciones que permitan ajustar el filtro a la respuesta deseada en un tiempo reducido.

Como punto de partida, se va a utilizar un filtro de orden 3 cuya frecuencia central es 17 GHz y su ancho de banda 400MHz. Sus dimensiones son las siguientes:

Guía de entrada y salida (mm)		Longitud de los resonadores (mm)		Apertura del iris (mm)	
Anchura	10	Resonador 1 y 3	13.07	Iris 1 y 4	7.75
Altura	5	Resonador 2	14.70	Iris 2 y 3	6.38

Tabla 2-2: Dimensiones filtro orden 3.

La estructura del filtro, así como su respuesta de parámetros S, se muestra a continuación:




Fig. 2-4: Estructura filtro orden 3.




Fig. 2-5: Respuesta filtro orden 3.

La red neuronal a diseñar deberá ser capaz de simular la respuesta de parámetros S (módulo de la transmisión y reflexión) de un filtro de iris en guía de onda de orden 3. Recibirá como argumentos de entrada la longitud de los resonadores y la apertura de los iris.

Las entradas de la red neuronal son las aperturas de los iris (w_1 y w_2) y las longitudes de las cavidades (l_1 y l_2). No confundir w con la matriz de pesos de la red neuronal definida anteriormente.

En cambio, la frecuencia y las dimensiones de la guía se mantendrán fijas en cada red. Se necesitarán por tanto tantas redes neuronales como frecuencias a evaluar




Fig. 2-6: Estructura de la red neuronal.

Sólo es necesario calcular el módulo de S_{11} o el de S_{21} puesto que el otro se puede calcular a partir del primero ya que es una estructura recíproca y sin pérdidas de manera que se cumple que $|S_{21}|^2 + |S_{11}|^2 = 1$.




Fig. 2-7: Estructura de la red neuronal simplificada.

2.3 Obtención de los datos de entrenamiento

Para obtener los datos de entrenamiento, test y validación se utiliza el simulador electromagnético *CST Microwave Studio*. Los datos se importan a *Matlab* donde son tratados para utilizarlos en el entrenamiento de la red neuronal.

La simulación electromagnética realizada en CST consiste en la caracterización de un iris para obtener su respuesta de parámetros S (módulo y fase) y exportarla a un fichero de tipo .s2p. Esta caracterización se realiza para diferentes valores de apertura de iris.

El script de *Matlab* carga los datos de los diferentes archivos .s2p obtenidos así como los correspondientes valores de las longitudes de los resonadores deseadas (en este caso se varían entre 10 y 14 mm). Se crea entonces una estructura que contiene toda la información necesaria para la red neuronal y que será usada en el entrenamiento: w_1 , w_2 , l_1 , l_2 , f , $|S_{11}|$ y $|S_{21}|$.

El script de *Matlab* hace una concatenación de las distintas matrices de parámetros S y construye el filtro deseado.




Fig. 2-8: Estructura utilizada para la caracterización del iris.

2.4 Simulación de filtro completo

A continuación se va a llevar a cabo la simulación de todo el filtro completo, de manera que los parámetros de entrada de la red neuronal van a ser las aperturas de los iris (w_1 y w_2) y las longitudes de los resonadores (l_1 y l_2).

La estructura del filtro completo se muestra a continuación, y es la que se va a intentar reproducir en las siguientes redes neuronales.




Fig. 2-9: Estructura del filtro completo que se reproduce con redes neuronales.

2.4.1 Red neuronal 1 – Filtro completo y red independiente de la frecuencia

Como primera estrategia se va a implementar la siguiente red neuronal:




Fig. 2-10: Estructura de la red neuronal del diseño 1.

Puesto que la frecuencia es fija para cada red neuronal, es decir, cada red neuronal está asociada a una frecuencia, se necesitarán tantas redes neuronales como puntos en frecuencia se hayan definido.

Tras varias pruebas se decide utilizar una única capa oculta con 15 neuronas.

Cada red se va a entrenar con 10500 puntos. En los que se varía w desde 5.2 hasta 9.7 mm y l desde 10 hasta 18 mm.

Proceso de entrenamiento con el *toolbox* de *Matlab*:

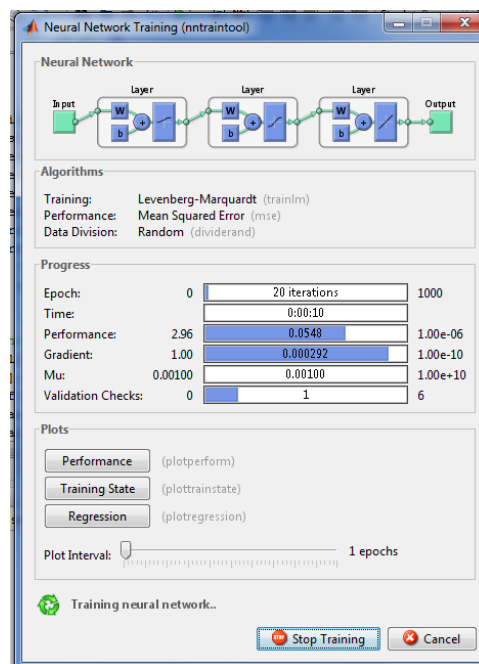


Fig. 2-11: Entrenamiento de una red neuronal con Matlab.

Los resultados que se obtienen son:




Fig. 2-12: Comparación de la transmisión del diseño 1.




Fig. 2-13: Comparación de la reflexión del diseño 1.

Se puede observar cómo ni la reflexión ni la transmisión se acercan a los resultados esperados. El error obtenido es muy elevado y la red entrenada no sirve para simular el comportamiento del filtro.

2.4.2 Red neuronal 2 – Filtro completo y red dependiente de la frecuencia

Se va a probar en este diseño a incluir la frecuencia como variable de entrada de la red neuronal. Se tiene por tanto una única red neuronal puesto que la frecuencia pasa a ser un parámetro de entrada. La estructura deseada es la siguiente:




Fig. 2-14: Estructura de la red neuronal del diseño 2.

Se lleva a cabo el entrenamiento de la red y se simula para los valores deseados. Se obtiene la siguiente respuesta:




Fig. 2-15: Comparación de la transmisión para el diseño 2.




Fig. 2-16: Comparación de la reflexión para el diseño 2.

En este caso, los datos de entrenamiento utilizados han sido 6400 valores en los que se ha variado w desde 5.2 hasta 9.7 y l desde 10.5 hasta 17.5. Se ha intentado aumentar el número de datos de entrenamiento e incluir todos los que se utilizaron para el caso anterior, pero esto genera un error en *Matlab* debido a que se queda sin memoria.

2.4.3 Conclusiones

A la vista de los resultados obtenidos en los diseños anteriores se puede ver como las redes entrenadas a partir de los datos de un filtro completo (w_1, w_2, l_1, l_2) no son capaces de reproducir el comportamiento esperado. Se va a proceder ahora a diseñar redes neuronales que reproduzcan el comportamiento de un iris únicamente.

2.5 Caracterización de iris

En este apartado se pretende entrenar redes neuronales que sean capaces de caracterizar el comportamiento de un iris en función de la apertura del mismo y la frecuencia. Con los resultados obtenidos de la caracterización (parámetros S) se pasa a concatenar las diferentes matrices en función de las longitudes de los resonadores, obteniéndose así el filtro completo.

Las siguientes redes neuronales simulan el comportamiento de la siguiente estructura:




Fig. 2-17: Iris caracterizado a través de redes neuronales.

2.5.1 Red neuronal 1

En este diseño se utilizan cuatro redes neuronales para caracterizar un iris. La entrada de todas ellas es la apertura del iris y la frecuencia. La salida es un único parámetro: parte real o imaginaria de la reflexión o transmisión. Se muestra a continuación la estructura de las redes a diseñar:




Fig. 2-18 Estructura de las redes neuronales para la caracterización de un iris (diseño 1).

Una vez obtenida la caracterización del iris se procede a calcular la respuesta completa del filtro mediante conexión en cascada de las diferentes matrices de parámetros S. Se obtiene lo siguiente:




Fig. 2-19: Comparación de la transmisión para el diseño 1.




Fig. 2-20: Comparación de la reflexión para el diseño 1.

Se puede observar como la respuesta obtenida es la esperada. Así, la red neuronal es capaz de reproducir el comportamiento del iris.

2.5.2 Red neuronal 2

En este diseño se va a utilizar como parámetros de salida el módulo y la fase, en lugar de la parte real e imaginaria.

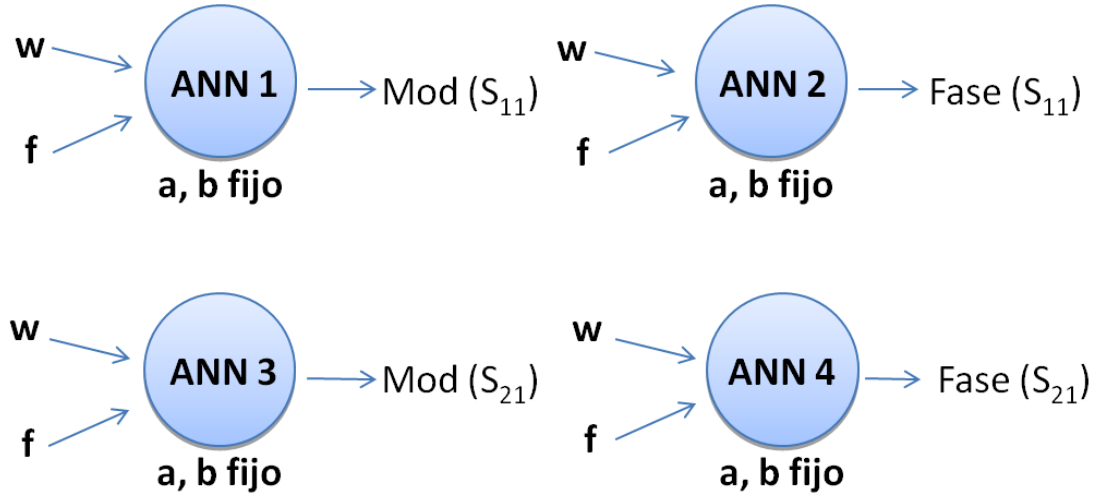


Fig. 2-21: Estructura de las redes neuronales para la caracterización de un iris (diseño 2).

No es necesario tener módulo y fase de S_{21} y S_{11} , con dos de ellos será suficiente según las ecuaciones siguientes, las cuales se cumplen para un circuito recíproco, simétrico y sin pérdidas:

$$[S] = \begin{pmatrix} |S_{11}| e^{j\theta_{11}} & \sqrt{1 - |S_{11}|^2} e^{j\theta_{12}} \\ \sqrt{1 - |S_{11}|^2} e^{j\theta_{12}} & |S_{11}| e^{j\theta_{11}} \end{pmatrix} \quad (2.5)$$

$$\theta_{12} = \theta_{11} + \frac{\pi}{2} \pm n\pi \quad n = 0, 1, 2, \dots \quad (2.6)$$

Se lleva a cabo el entrenamiento de la red y posterior interconexión de matrices, y se obtiene la siguiente respuesta:




Fig. 2-22: Comparación de la transmisión para el diseño 2.




Fig. 2-23: Comparación de la reflexión para el diseño 2.

A la vista de las gráficas anteriores se observa como la red neuronal también es capaz de conseguir los resultados obtenidos a través de la simulación electromagnética.

Las gráficas siguientes muestran la caracterización de dos iris de cuyos valores de apertura son de 7.76 mm y 6.375 mm. Se puede observar cómo tanto el módulo como la fase que se obtienen son prácticamente iguales. La red neuronal reproduce fielmente el comportamiento del iris por lo que al llevar a cabo la construcción del filtro completo la respuesta es la deseada.

La gráfica que caracteriza un iris es mucho más fácil de reproducir que la respuesta de un filtro. Esto explica que la red neuronal del apartado anterior no sea capaz de reproducir el comportamiento del filtro completo.





Fig. 2-24: Caracterización de un iris de apertura 7.76 mm. Módulo y Fase.



2.5.3 Red neuronal 3

En este diseño se va a quitar la frecuencia como parámetro de entrada de la red neuronal, de manera que cada red sólo depende de la apertura del iris. Existirán por tanto tantas redes neuronales como puntos de frecuencia. Además, como ocurría antes, existirá una red para cada módulo y otra para cada fase de la reflexión y de la transmisión.

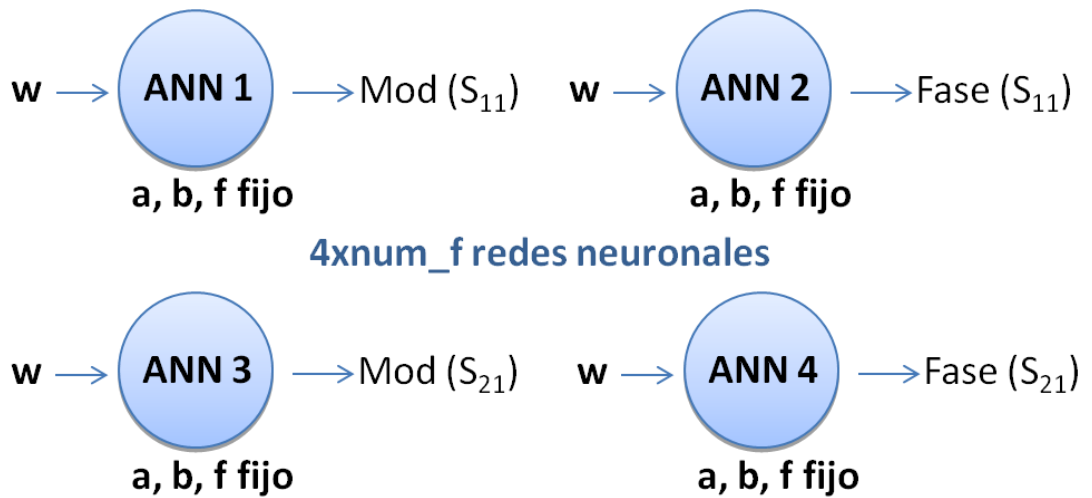


Fig. 2-26: Estructura de las redes neuronales para la caracterización de un iris (diseño 3).

Los resultados obtenidos tras la construcción del filtro completo son los que aparecen a continuación:





Fig. 2-27 Comparación de la transmisión para el diseño 3.



Se puede observar como la respuesta obtenida con la red neuronal se acerca a la deseada pero tiene mucho error, especialmente la reflexión. La red neuronal no es capaz de entrenar bien el modelo.

Se muestra a continuación la caracterización de cada iris, al igual que se presentó en el diseño anterior. Se ve como el error que existe es elevado y la respuesta de la red no se ajusta a la obtenida en CST.




Fig. 2-29: Caracterización de un iris de apertura 7.76 mm. Módulo y Fase.




Fig. 2-30: Caracterización de un iris de apertura 6.375 mm. Módulo y Fase.

2.5.4 Red neuronal 4

En este diseño y en el siguiente la red neuronal tendrá cuatro salidas (módulo y fase de la reflexión y transmisión), en lugar de una red para cada una de ellas. En este primer diseño la frecuencia no será un parámetro de entrada por lo que habrá tantas redes neuronales como puntos de frecuencia.




Fig. 2-31: Estructura de la red neuronal para la caracterización de un iris (diseño 4).

La respuesta obtenida para el filtro completo es la siguiente:




Fig. 2-32: Comparación de la transmisión para el diseño 4.




Fig. 2-33: Comparación de la reflexión para el diseño 4.

La respuesta obtenida tiene mucho error y la red no es capaz de cumplir con la respuesta esperada.

Si se observa la caracterización de un iris se puede ver cómo la red presenta un error elevado.




Fig. 2-34: Caracterización de un iris de apertura 7.76 mm. Módulo y Fase.




Fig. 2-35: Caracterización de un iris de apertura 6.375 mm. Módulo y Fase.

2.5.5 Red neuronal 5

En este diseño se incluye la frecuencia como parámetro de entrada de manera que tendremos una única red que será capaz de caracterizar un iris. La estructura de la red es la siguiente:




Fig. 2-36: Estructura de las redes neuronales para la caracterización de un iris (diseño 5).




Fig. 2-37: Comparación de la transmisión para el diseño 5.




Fig. 2-38: Comparación de la reflexión para el diseño 5.

Se puede observar como la respuesta en frecuencia del filtro completo reproduce la respuesta esperada. Si se observa la caracterización de cada iris se ve que el error es muy pequeño.




Fig. 2-39: Caracterización de un iris de apertura 7.76 mm. Módulo y Fase.




Fig. 2-40: Caracterización de un iris de apertura 6.375 mm. Módulo y Fase.

2.5.6 Conclusiones

A la vista de los diseños anteriores en los cuales se ha tratado de caracterizar un iris mediante redes neuronales, se ha demostrado que la salida de la misma puede ser tanto el módulo y la fase de la reflexión y transmisión como la parte real e imaginaria de los mismos.

Si la frecuencia no se incluye como parámetro de entrada de la red neuronal, ésta no logrará entrenar bien y el error será elevado, por lo que no se conseguirá la respuesta deseada.

Si la red neuronal tiene como parámetros de entrada la apertura del iris y la frecuencia, la respuesta será la esperada y la red quedará bien entrenada. Se puede además incluir en esa red todas las salidas ($\text{real}(S_{11})$, $\text{imag}(S_{11})$, $\text{real}(S_{21})$ e $\text{imag}(S_{21})$) de manera que se puede caracterizar un iris con una única red neuronal.

3 Diseño de acopladores

3.1 Fundamentos teóricos de los acopladores

Los acopladores direccionales son componentes pasivos de microondas usados para dividir potencia de manera arbitraria entre cada puerto [1].

Son redes de cuatro puertos. La figura siguiente muestra el símbolo utilizado y la definición de los puertos:




Fig. 3-1: Símbolo acopladores direccionales.

En los acopladores direccionales, si se hace incidir potencia por el puerto 1, ésta se acopla en el puerto 2 y 3, pero no en el 4. De manera análoga, si la potencia incide en el puerto 4, ésta se acopla en el puerto 2 y 3, pero no en el 1. Así, los puertos 1 y 4 están desacoplados. Si la potencia incide por 2 ó 3 la potencia se acopla sólo en los puertos 1 y 4. Además los cuatro puertos están adaptados.

Un acoplador direccional ideal tendrá la siguiente matriz de parámetros S:

$$[S] = \begin{pmatrix} 0 & S_{21} & S_{31} & 0 \\ S_{21} & 0 & 0 & S_{31} \\ S_{31} & 0 & 0 & S_{21} \\ 0 & S_{31} & S_{21} & 0 \end{pmatrix} \quad (3.1)$$

Donde:

$$|S_{21}|^2 + |S_{31}|^2 = 1 \quad (3.2)$$

A la hora de caracterizar un acoplador se usan los siguientes parámetros:

Acoplo: Mide la fracción de potencia de la entrada que se acopla en el puerto de salida. Se define como potencia incidente en el puerto 1 entre la potencia acoplada en el puerto 3.

$$C = 10 \cdot \log \frac{P_1}{P_3} = -20 \cdot \log |S_{31}| \quad (\text{dB}) \quad (3.3)$$

Directividad: Mide la capacidad que tiene el acoplador de aislar las ondas que van en un sentido y en otro en la segunda guía. Es el cociente entre la potencia acoplada en el puerto 3 (puerto acoplado) y en el 4 (puerto aislado). Idealmente la potencia acoplada en el puerto 4 es cero.

$$D = 10 \cdot \log \frac{P_3}{P_4} = 20 \cdot \log \frac{|S_{31}|}{|S_{41}|} \quad (\text{dB}) \quad (3.4)$$

Aislamiento: Es el cociente entre la potencia que incide por el puerto 1 y la que se acopla por el puerto 4.

$$I = 10 \cdot \log \frac{P_1}{P_4} = -20 \cdot \log |S_{41}| \quad (\text{dB}) \quad (3.5)$$

Estos tres parámetros quedan relacionados según la siguiente ecuación: acopla por el puerto 4.

$$I = D + C \quad (\text{dB}) \quad (3.6)$$

Un acoplador ideal tendrá infinita directividad y aislamiento puesto que $S_{14} = 0$. En función del valor de acoplo se puede determinar el valor de $|S_{21}|$ y $|S_{31}|$.

Acopladores híbridos.

Son un caso especial de acopladores direccionales donde el factor de acoplo es 3 dB. Así, $|S_{21}|$ y $|S_{31}|$ tendrán un valor de $1/\sqrt{2}$ en naturales. Existen dos tipos de acopladores híbridos:

- Acoplador híbrido 90° o en cuadratura. La diferencia de fase entre los puertos 2 y 3 es de 90° cuando se alimenta por el puerto 1. Es un acoplador simétrico. Un ejemplo es el acoplador *branchline*. Su matriz S es la siguiente:

$$[S] = \frac{1}{\sqrt{2}} \begin{pmatrix} 0 & 1 & j & 0 \\ 1 & 0 & 0 & j \\ j & 0 & 0 & 1 \\ 0 & j & 1 & 0 \end{pmatrix} \quad (3.7)$$

- Acoplador híbrido 180°. Un ejemplo es la T mágica o los *rat-race*. Es un acoplador antisimétrico en el que la diferencia de fase entre los puertos 2 y 3 es 180° cuando se alimenta por el puerto 4. Su matriz S es la siguiente:

$$[S] = \frac{1}{\sqrt{2}} \begin{pmatrix} 0 & 1 & 1 & 0 \\ 1 & 0 & 0 & -1 \\ 1 & 0 & 0 & 1 \\ 0 & -1 & 1 & 0 \end{pmatrix} \quad (3.8)$$

A continuación se muestran algunos ejemplos de acopladores en guía de onda:

- *Bethe Hole Coupler*. Consiste en utilizar dos guías separadas de manera que se acople la potencia mediante un pequeño agujero entre ellas, en la pared que comparten. La manera de conseguir la respuesta deseada se logra mediante el uso de dos componentes de onda separadas de tal forma que se suman en fase en la puerta acoplada y se cancelan en la aislada.
- *Multihole Coupler*. El acoplador anterior muestra una respuesta de banda estrecha en cuanto a la directividad. Para lograr una respuesta de mayor ancho de banda se realizan más agujeros de acoplo separándolos $\lambda_g / 4$.




Fig. 3-2: Multihole Coupler.

- *Moreno crossed-guide coupler*. Consiste en dos guías de onda que se colocan formando un ángulo recto. El acoplo se realiza a través de dos aperturas en la pared común. Estas aperturas suelen ser ranuras en forma de cruz.




Fig. 3-3: Moreno crossed-guide coupler (de [1]).



En este capítulo se va a llevar a cabo el diseño de algunos acopladores para su uso en el capítulo siguiente. Los acopladores que se van a utilizar son los de tipo *branch line* en guía de onda. Estos son acopladores híbridos 90° por lo que la potencia se divide de igual manera entre el puerto directo y el acoplado, siendo el $|S_{21}| = |S_{31}| = 3 \text{ dB}$. Además la diferencia de fase entre los puertos 2 y 3 es de 90° . La matriz de parámetros S ideal de estos dispositivos es la siguiente:

$$[S] = \frac{1}{\sqrt{2}} \begin{pmatrix} 0 & 1 & j & 0 \\ 1 & 0 & 0 & j \\ j & 0 & 0 & 1 \\ 0 & j & 1 & 0 \end{pmatrix} \quad (3.9)$$

Las guías de onda que se van a utilizar para alimentar los diferentes puertos son del tipo WR51 cuyas dimensiones son: ancho de guía igual a 12.951 mm y altura 6.47 mm.

3.2 Diseño de un acoplador híbrido de 2 ramas

A continuación se va a diseñar un acoplador híbrido de tipo *branch guide* de dos ramas (orden 1). La estructura de la que se parte es la siguiente:

Fig. 3-4: Acoplador híbrido *branch guide* orden 1.Fig. 3-5: Esquema del acoplador híbrido *branch guide* orden 1.

Las variables que no se conocen y hay que obtener son l_0 , w_0 e y_0 . Se va a realizar el cálculo mediante barridos paramétricos y optimización buscando que la reflexión ($|S_{11}|$) y el aislamiento ($|S_{41}|$) sean lo más pequeño posible. Además, la potencia entregada al puerto 2 y 3 deber ser igual. Buscando estos cumplir estos requisitos se obtienen los siguientes valores:

Variable	l_0	w_0	y_0
Valor (mm)	9	9.5	9

Tabla 3-1: Dimensiones del acoplador de orden 1.

La respuesta que se obtiene, tanto en módulo como en fase es la siguiente:




Fig. 3-6: Respuesta del acoplador de orden 1 (módulo).




Fig. 3-7: Respuesta del acoplador de orden 1 (fase).

Se puede observar como los valores de reflexión y aislamiento no son muy buenos, tomando valores de unos -15 dB.

Habr  que aumentar el orden del acoplador para conseguir una respuesta mejor.

La diferencia de fase entre las se ales que llegan al puerto 2 y 3 cuando se alimenta por el puerto 1 es de 88.6 .

3.3 Diseño de un acoplador híbrido orden 2 – 3 ramas

Se aumenta el orden del acoplador, colocando una rama más. Ahora, la estructura que se busca optimizar es la siguiente:




Fig. 3-8: Acoplador híbrido *branch guide* orden 2.




Fig. 3-9: Esquema del acoplador híbrido *branch guide* orden 2.

Aparecen 4 variables a optimizar, cuyos valores obtenidos son los siguientes:

Variable	l_0	l_1	w_0	y_0
Valor (mm)	7	2.5	4.75	9

Tabla 3-2: Dimensiones del acoplador de orden 2.

La respuesta que se obtiene es la siguiente:




Fig. 3-10: Respuesta del acoplador de orden 2 (módulo).




Fig. 3-11: Respuesta del acoplador de orden 2 (fase).

En este caso se puede observar como el aislamiento y la reflexión es mucho mejor que antes, y se acerca a -30 dB. La potencia que se divide entre cada puerto es la misma y la diferencia de fase entre la señal recibida en los puertos 2 y 3 es de 90°.

3.4 Diseño de un acoplador híbrido orden 3 – 4 ramas

Se va diseñar a continuación un acoplador de orden 3. Aparecen seis variables a optimizar. La estructura es la siguiente:




Fig. 3-12: Acoplador híbrido *branch guide* orden 3.




Fig. 3-13: Esquema del acoplador híbrido *branch guide* orden 3.

Variable	l_0	l_1	w_0	w_1	y_0	y_1
Valor (mm)	6.3	2.3	5.95	8.2	9	9

Tabla 3-3: Dimensiones del acoplador de orden 3.

La respuesta que se obtiene es la siguiente:




Fig. 3-14: Respuesta del acoplador de orden 3 (módulo).




Fig. 3-15: Respuesta del acoplador de orden 3 (fase).

A la vista de los resultados se observa que el valor del aislamiento y la reflexión es muy bueno, mejor que para el caso de 3 ramas. Se consiguen valores de -55 dB en la frecuencia central, frente a los apenas -30 dB del caso anterior.

La diferencia de fase éntrelos puertos 2 y 3 es de 90° cuando se alimenta el acoplador por el puerto 1.

4 Diseño de acopladores en guía de onda a través de redes neuronales

4.1 Introducción

En este capítulo se pretende diseñar y entrenar redes neuronales que sean capaces de calcular la respuesta de parámetros S de acopladores, es decir, se va a llevar a cabo la simulación electromagnética de acopladores mediante redes neuronales.

Para llevar a cabo el entrenamiento se han diseñado acopladores híbridos en guía de onda de diferentes órdenes. Todos ellos utilizan guías del tipo WR51 cuya anchura es 12.954 mm y altura 6.477 mm.

4.2 Caracterización de un acoplador de orden 2

Se pretende construir una red neuronal que sea capaz de simular el comportamiento de un acoplador en guía de onda de 3 ramas. La estructura es la siguiente:





Fig. 4-1: Estructura del acoplador de orden 2.

Las variables de diseño son w_0 , l_0 , l_1 e y_0 , las cuales coinciden con las variables de entrada de la red neuronal. Los valores de salida serán el módulo de los parámetros S_{11} , S_{21} , S_{31} y S_{41} . Habrá tantas redes neuronales como puntos de frecuencia. La estructura de la red neuronal es la siguiente:



num_f redes neuronales

Fig. 4-2: Estructura de la red neuronal.

Para llevar a cabo el entrenamiento de la red neuronal se parte de 535 posibles configuraciones de l_0 , l_1 , w_0 e y_0 , con sus 1001 correspondientes puntos de frecuencia. Así, se entrena la red con 535535 datos de entrada. Estos se corresponden con la respuesta del acoplador para valores de l_0 entre 5 y 9, de l_1 entre 1 y 4, de w_0 entre 2 y 5 y de y_0 entre 7 y 9. La red se entrena en total con 535535 vectores de entrada.

Una vez llevado a cabo el entrenamiento se procede a simular la respuesta para los valores de entrada correspondientes al acoplador objetivo. Los valores del acoplador objetivo se obtuvieron en el capítulo anterior y son:

Variable	l_0	l_1	w_0	y_0
Valor (mm)	7	2.5	4.75	9

Tabla 4-1: Datos del acoplador objetivo.

La respuesta objetivo es la siguiente:




Fig. 4-3: Respuesta del acoplador objetivo.

Si se realiza el cálculo de la respuesta para dichos parámetros en la red neuronal se obtiene lo siguiente:




Fig. 4-4: Respuesta S_{11} de la red entrenada (1001 puntos).




Fig. 4-5: Respuesta S_{21} de la red entrenada (1001 puntos).




Fig. 4-6: Respuesta S_{31} de la red entrenada (1001 puntos).




Fig. 4-7: Respuesta S_{41} de la red entrenada (1001 puntos).

En rojo se superpone la respuesta que se obtiene con el simulador electromagnético (CST *Microwave Studio*), y que es la que se espera obtener con la red.

Se puede observar que la respuesta obtenida no es la esperada y tiene un error bastante elevado. Este efecto ya ocurría con los filtros al diseñar tantas redes neuronales como puntos de frecuencia.

A continuación se va a proceder a disminuir el número de puntos de frecuencia. Si se cogen únicamente 101 puntos en lugar de 1001, la respuesta queda:




Fig. 4-8: Respuesta S_{11} de la red entrenada (101 puntos).




Fig. 4-9: Respuesta S_{21} de la red entrenada (101 puntos).




Fig. 4-10: Respuesta S_{31} de la red entrenada (101 puntos).




Fig. 4-11: Respuesta S_{41} de la red entrenada (101 puntos).

Si sólo se cogen 14 puntos, la respuesta que se obtiene es la siguiente:




Fig. 4-12: Respuesta S_{11} de la red entrenada (14 puntos).




Fig. 4-13: Respuesta S_{21} de la red entrenada (14 puntos).




Fig. 4-14: Respuesta S_{31} de la red entrenada (14 puntos).




Fig. 4-15: Respuesta S_{41} de la red entrenada (14 puntos).

Se puede observar que conforme se reduce el número de puntos en la simulación, la red neuronal tiene una respuesta similar a la deseada, logrando la red neuronal reproducir el comportamiento del acoplador.

4.3 Red dependiente de la frecuencia

Para el diseño de la siguiente red neuronal, encargada de reproducir el comportamiento de un acoplador de orden 2, la frecuencia va a ser también un parámetro de entrada. Sólo habrá una salida para cada red neuronal (S_{11} , S_{21} , S_{31} o S_{41}). Por ello, existirán 4 redes neuronales a entrenar. La estructura de la red queda de la siguiente manera:




Fig. 4-16: Estructura de la red neuronal dependiente de la frecuencia.




Fig. 4-17: Respuesta S_{11} de la red entrenada.




Fig. 4-18: Respuesta S_{21} de la red entrenada.




Fig. 4-19: Respuesta S_{31} de la red entrenada.




Fig. 4-20: Respuesta S_{41} de la red entrenada.

En este caso, la red neuronal tiene como parámetro de entrada la frecuencia y la salida es un único parámetro. Ésta reproduce el comportamiento del acoplador sin necesidad de reducir el número de puntos de la simulación.

5 Diseño de filtros mediante mapeado espacial

5.1 Fundamentos teóricos del *space mapping*

En este capítulo se van a utilizar técnicas de *space mapping* o *mapeado espacial* para optimizar filtros de microondas [9]. Se pretender llevar a cabo diseños ayudados por optimización más rápidos que con los softwares comerciales de simulación electromagnética.

Las técnicas de mapeado espacial utilizan dos modelos:

- Modelo fino: Es lento y costoso en recursos pero muy preciso (ADS, HFSS...).
- Modelo grueso: Es rápido y de poco coste computacional pero menos preciso (ADS, Matlab...).

Existen muchas técnicas de optimización a través de métodos de *space mapping*: *implicit space mapping*, *output space mapping*, *tunning space mapping*, *aggressive space mapping*... Todas ellas siguen los siguientes pasos:

- Simulación en el modelo fino (verificación).
- Extracción de los parámetros del modelo fino al grueso.
- Actualización del modelo grueso.
- Reoptimización del modelo grueso.

La técnica que se va a utilizar es la de *aggressive space mapping* [10].

Las técnicas de *mapeado espacial* se han desarrollado para modelos en los que se requieren funciones de evaluación costosas. En ellas se asume que existen dos modelos diferentes del mismo sistema físico, uno fino (costoso a nivel computacional y preciso) y otro grueso (menos preciso y más rápido).

La idea principal es utilizar el modelo grueso para conseguir información adicional sobre el modelo fino y utilizarla para la búsqueda de la solución óptima. Se establece por tanto un mapeado entre los parámetros de los dos modelos que relaciona las respuestas, permitiendo reducir el número de evaluaciones en el modelo fino.

En muchas ocasiones, esta técnica proporciona rápidamente una solución óptima que es suficientemente precisa para los propósitos buscados en ingeniería.

La gráfica siguiente muestra en qué consiste el modelo fino y el grueso así como la relación entre ellos.

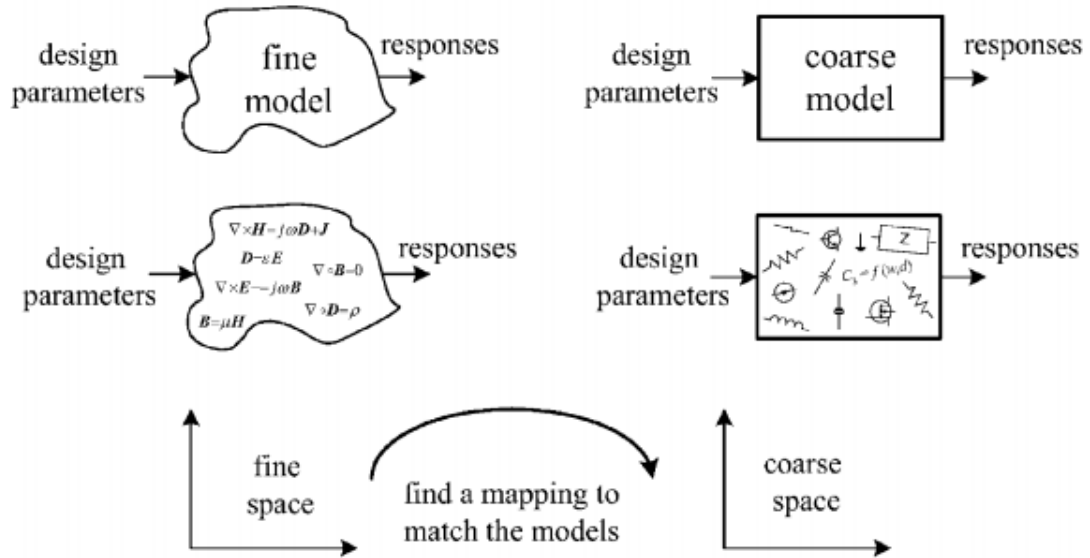


Fig. 5-1: Modelo fino y grueso en el mapeado espacial (de [7]).

Las técnicas de *space mapping* tratan de encontrar los parámetros del modelo fino que cumplen las especificaciones del diseño. Sin embargo, puesto que es un modelo costoso no se puede llevar a cabo una optimización directa. Se utiliza por tanto el modelo grueso para ganar información. El funcionamiento se puede explicar a través del siguiente ejemplo:

Un arquero trata de acertar con su flecha al centro de una diana. Apunta y dispara, fallando el tiro. Esta desviación se debe a que el arquero no tuvo en cuenta la fuerza del viento ni la gravedad. En el siguiente disparo decide tenerlos en cuenta. Por ello, apunta en una dirección distinta a donde disparó la primera flecha.

En el caso del *space mapping* la idea es similar. Inicialmente se tiene un punto en el espacio grueso (T_g) que se desea alcanzar. Este punto cumple las especificaciones en el modelo grueso (el cual no es muy preciso). Se fija un punto objetivo en el espacio fino (Tf_1) que será igual al del espacio grueso. Puesto que el modelo fino incluye efectos que no se tienen en cuenta en el modelo grueso, al obtener el nuevo punto (x_c) en el modelo fino se observa que existe un error con respecto al punto óptimo buscado (T_g). Debido a esto, se lleva a cabo una reoptimización del punto objetivo fino, la cual se basa, según el ejemplo del arquero, en corregir esa desviación. El nuevo punto objetivo en el espacio fino (Tf_2) será por tanto $Tf_2 = Tf_1 + (x_c - T_g)$. Este proceso se repite hasta que x_c cumple las especificaciones del modelo fino.

La figura siguiente muestra el modelo fino y el grueso junto con las variables que intervienen en cada uno.

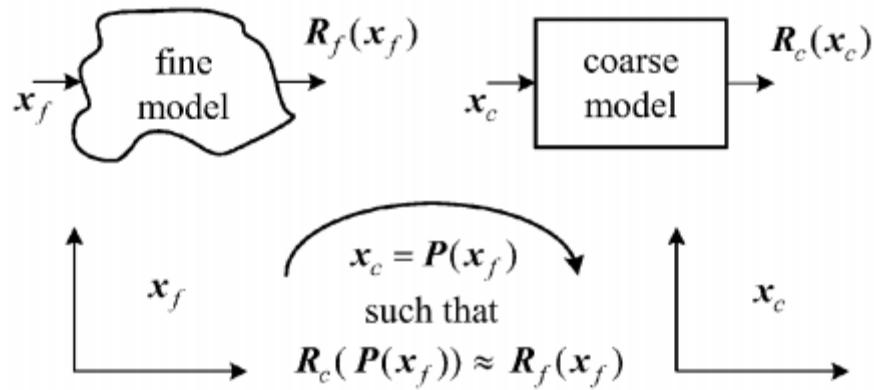


Fig. 5-2: Relación entre el modelo fino y el grueso de ([7]).

Se busca encontrar el mapeado P entre el modelo fino y el grueso, de manera que la respuesta del modelo fino se corresponda con la respuesta del modelo grueso obtenida tras la conversión del modelo fino al grueso.

5.2 Esquema de funcionamiento

El esquema de funcionamiento es el siguiente:

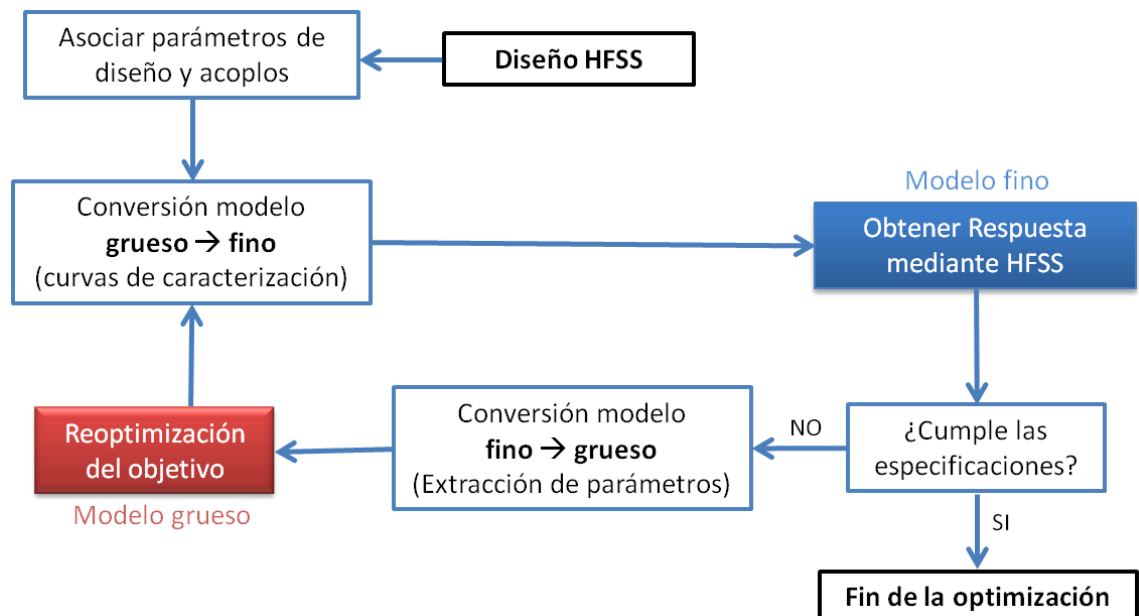


Fig. 5-3: Esquema de funcionamiento del mapeado espacial propuesto.

1. Se parte de un diseño en HFSS cuya respuesta se busca optimizar para que cumpla las especificaciones.
2. Asociar los diferentes acoplos con los parámetros de diseño en HFSS (longitud de los resonadores, apertura de los iris...).
3. Traducción del modelo grueso al modelo fino, actualizando los parámetros de diseño en HFSS.
4. Simular el diseño para obtener su respuesta de parámetros S. Simulación lenta y costosa al llevarse a cabo en el modelo fino.
5. Comprobar los requisitos de diseño. Si se cumplen se termina el proceso de optimización. En caso contrario se continúa con la optimización.
6. Extracción de parámetros, obteniendo la matriz de acoplo del diseño.
7. Reoptimizar el modelo grueso utilizando la técnica de ASM (*aggressive space mapping*) junto con una actualización de tipo *Broyden*.
8. Repetir el paso 3.

Gracias a esto, en nuestro problema de diseño de circuitos de microondas, la información adicional del modelo grueso permite reducir el número de simulaciones precisas en el simulador comercial HFSS, reduciendo así el tiempo de optimización necesario.

5.2.1 Asociación de parámetros mediante curvas de caracterización

Para llevar a cabo la conversión del modelo grueso (matrices de acoplo) al modelo fino (parámetros físicos del diseño) es necesario indicar al programa qué factores de la matriz M se corresponden con cada una de las variables de diseño, de manera que puedan ser modificadas en función de los resultados que se vayan obteniendo. Esto se lleva a cabo mediante curvas de caracterización, las cuales indican cómo se comporta la estructura al variar un parámetro en concreto. Es un paso fundamental puesto que permite establecer el mapeado entre el modelo fino y el grueso.

Curvas Características

Q_entrada.csv

fres1.csv

fres2.csv

fres3.csv

k.csv

Cargar curvas

Eliminar curva

Mostrar curva

Eliminar todas

Parámetros de diseño

yv2

xch1

xv23

ycav3

xcv34

ycav4

xcv45

ycav5

ycav2

xv1011

xcav11

ycav11

Asociar var >>

Eliminar <<

Eliminar todas

☐ Mostrar variables dependientes

	Curva	Variable	Unidades	Factores de acoplo
1	Q_entrada.csv	yv01	mm	E
2	Q_entrada.csv	yv1011	mm	S
3	fres1.csv	xcav1	mm	M1,1
4	fres1.csv	xcav5	mm	M5,5
5	fres2.csv	xcav2	mm	M2,2
6	fres2.csv	xcav4	mm	M4,4
7	fres3.csv	xcav3	mm	M3,3
8	k.csv	yv12	mm	MD1,2
9	k.csv	yv23	mm	MD2,3
10	k.csv	yv34	mm	MD3,4
11	k.csv	yv45	mm	MD4,5

Fig. 5-4: Asociación de parámetros entre el modelo fino y grueso.

Esto implica que es necesario obtener previamente una serie de curvas de caracterización que relacionen los acoplos y las variables de diseño. Éstas se obtienen del diseño HFSS a optimizar. Son necesarias tres curvas:

- Curvas de frecuencias de resonancias. Dependerá del tipo de diseño. La frecuencia de resonancia puede variar en función de la longitud de la cavidad, de la inserción de un tornillo de sintonización...

Se llevará a cabo un barrido paramétrico en una simulación de tipo *EigenMode* con un único modo de propagación.

- Curvas de factores de acoplo interno, a través de sondas o ventanas. Se calcularán las frecuencias de resonancia de los dos primeros modos de la estructura mediante una simulación de tipo *EigenMode* y realizando un barrido paramétrico de la variable física que determina el acoplo. El valor del acoplo entre cavidades se obtiene mediante la siguiente expresión:

$$k = 2 \cdot \frac{re(Mode(2)) - re(Mode(1))}{re(Mode(2)) + re(Mode(1))} \quad (5.1)$$

- Curvas de acoplo externo, entre la entrada y salida. Se lleva a cabo una simulación de tipo *DrivenModal*. El valor del factor de acoplo externo (Q_{ext}) se obtiene a través de las siguientes expresiones:

$$\tau_{s_{11}} = \max(GroupDelay(1,1)) \quad (5.2)$$

$$f_0 = XatY \max(GroupDelay(1,1)) \quad (5.3)$$

$$Q_{ext} = 2 \cdot \pi \cdot f_0 \cdot \tau_{s_{11}} / 4 \quad (5.4)$$

Se muestra a continuación un ejemplo de curva de acoplo interno:




Fig. 5-5: Curva de acoplo interno.

5.2.2 Conversión del modelo grueso al modelo fino

Consiste en realizar un mapeado entre la matriz de acoplo y las dimensiones físicas de la estructura. Esto se hace gracias a las curvas de caracterización obtenidas y a la asociación de parámetros previamente definida. El valor del acoplo es convertido en una dimensión física de un parámetro. A continuación se muestran dos ejemplos:

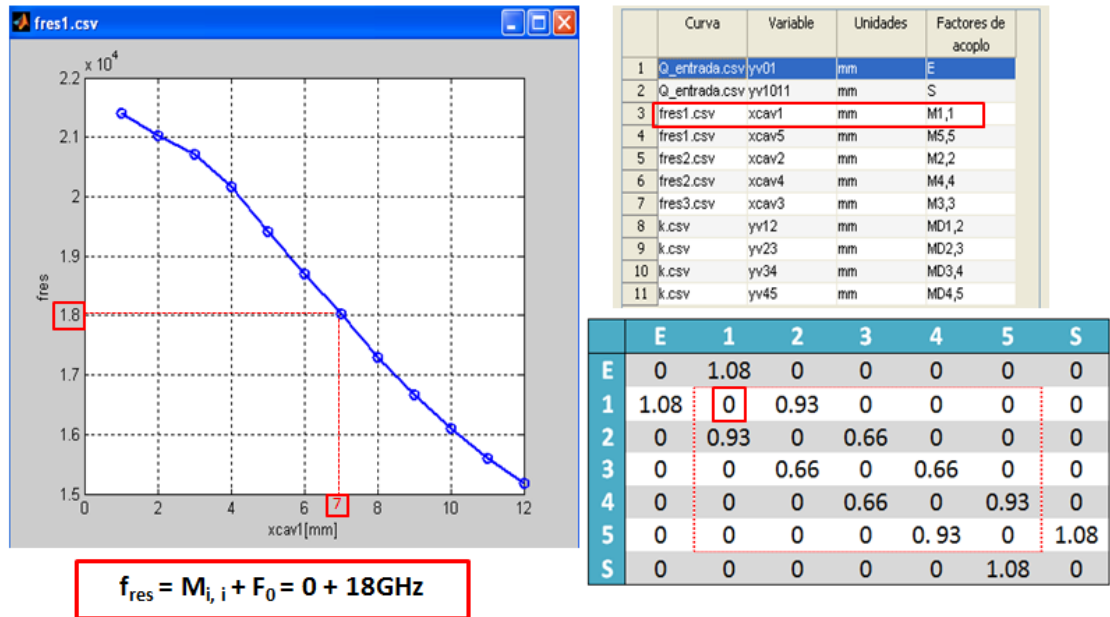


Fig. 5-6: Conversión del modelo grueso al fino. Frecuencias de resonancia.

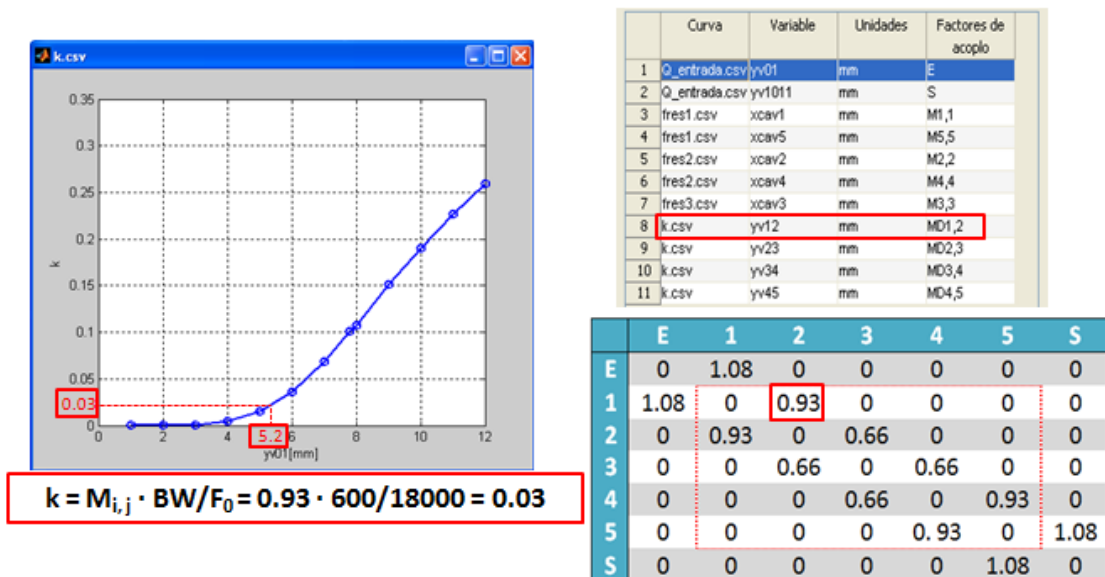


Fig. 5-7: Conversión del modelo grueso al fino. Acoplos directos.

5.2.3 Conversión del modelo fino al grueso

Consiste en la extracción de parámetros, es decir, pasar del espacio del modelo fino (dimensiones físicas de la estructura) al espacio del modelo grueso (matriz de acoplo). Para ello se usa una función que permite obtener una matriz M dada una respuesta de parámetros S. Se logra a través de una optimización de tipo Quasi-Newton.

5.2.4 Reoptimización del modelo grueso

Para llevar a cabo la reoptimización del modelo grueso se utiliza la técnica de *aggressive space mapping* mediante una actualización de tipo *Broyden* [11]. La reoptimización consiste en buscar el mapeado entre los dos espacios P de manera que se cumpla que:

$$\| R_f(x_f) - R_c(P(x_f)) \| \leq \varepsilon, \quad (5.5)$$

donde R_f es la respuesta del modelo fino, R_c es la respuesta del modelo grueso, $\| \cdot \|$ la norma correspondiente y ε la tolerancia permitida. La función de error vendrá dada por la siguiente expresión:

$$f = P(x_f) - x_c^* = x_c - x_c^* \quad (5.6)$$

El punto objetivo en el espacio grueso es x_c^* y $x_c^{(i)}$ es el punto en el espacio grueso. Si $f=0$ entonces se ha conseguido el modelo final y el mapeado está establecido correctamente. Si no es así, hay que seguir iterando. En la iteración i tenemos que:

$$x_f^{(i+1)} = x_f^{(i)} + h^{(i)} \quad (5.7)$$

Donde la actualización del modelo grueso se realiza a través de la matriz B que es la matriz de *Broyden*:

$$h^{(i)} = -\frac{f^{(i)}}{B^{(i)}} = -\frac{(x_c^{(i)} - x_c^*)}{B^{(i)}} \quad (5.8)$$

$$B^{(i+1)} = B^{(i)} + \frac{f^{(i+1)} h^{(i)T}}{h^{(i)T} h^{(i)}} \quad (5.9)$$

El nuevo punto del modelo se calcula por tanto con la siguiente ecuación:

$$x_f^{(i+1)} = x_f^{(i)} + (-\text{inv}(B^{(i)})) \cdot (x_c^{(i)} - x_c^*) \quad (5.10)$$

En la primera iteración B es una matriz identidad.

5.3 Funcionamiento

El modelo fino que se va a utilizar es HFSS, el cual ofrece una solución precisa pero lenta y costosa en simulación.

El modelo grueso va a ser el programa *Presto*, escrito en *Matlab*, el cual lleva a cabo una extracción de parámetros del filtro a través de la respuesta *.s2p*, generando la matriz de acoplo correspondiente y comparándola con la matriz objetivo.

Se parte por tanto de un diseño en un simulador electromagnético, en este caso HFSS, cuya respuesta de parámetros S no cumple las especificaciones de diseño. Dicha respuesta es cargada en Presto y se obtiene su matriz de acoplo mediante una optimización de tipo *Quasi-Newton*. A cada acoplo se le asocia una curva de caracterización con el modelo en HFSS de manera que se obtienen unas nuevas variables de diseño que son pasadas a HFSS para actualizar el modelo. Si la respuesta cumple las especificaciones se ha terminado, en caso contrario se vuelve a iniciar el ciclo y la respuesta de parámetros S es pasada a *Presto* donde se lleva a cabo la conversión entre el modelo fino y el grueso. Posteriormente se lleva a cabo la optimización en el modelo grueso mediante las matrices de acoplo

5.4 Ejemplo 1: Optimización de filtro de iris de orden 5

A continuación se va a optimizar mediante *aggressive space mapping* un filtro de iris en guía de onda de orden 5, el cual tiene una frecuencia central de 18 GHz y ancho de banda de 600MHz. El ancho de la guía de entrada es de 13.25 mm.

5.4.1 Filtro objetivo

El filtro objetivo que se busca conseguir tiene la siguiente respuesta de parámetros S:




Fig. 5-8: Filtro objetivo para el mapeado espacial.

Su matriz de acoplo (N+2) es la siguiente:

	E	1	2	3	4	5	S
E	0	1.078	0	0	0	0	0
1	1.078	0	0.929	0	0	0	0
2	0	0.929	0	0.663	0	0	0
3	0	0	0.663	0	0.663	0	0
4	0	0	0	0.663	0	0.929	0
5	0	0	0	0	0.929	0	1.078
S	0	0	0	0	0	1.078	0

Tabla 5-1: Matriz de acoplo objetivo.

5.4.2 Diseño HFSS

El diseño HFSS del que se parte es el siguiente:




Fig. 5-9: Filtro de irises a optimizar en HFSS.




Fig. 5-10: Variables del filtro de irises a optimizar.

Los parámetros físicos que se buscan optimizar son las aperturas de los irises ($yv01$, $yv12$, $yv23$, $yv34$, $yv45$ e $yv1011$) y las longitudes de los resonadores ($xcav1$, $xcav2$, $xcav3$, $xcav4$ y $xcav5$). La respuesta inicial del filtro es la siguiente:




Fig. 5-11: Respuesta inicial del filtro.

5.4.3 Obtención de las curvas de caracterización

Para llevar a cabo el mapeado entre el modelo fino y el modelo grueso es necesario obtener tres tipos de curvas:

- Curvas de frecuencia de resonancia de los resonadores
- Curvas de acoplo entre cavidades
- Curvas de acoplo entrada/salida

Frecuencias de resonancia. Se parte del modelo completo y se realiza una simulación de tipo *EigenMode* con un barrido paramétrico de la longitud del resonador correspondiente. Puesto que los resonadores 1 y 5 son iguales, así como 2 y 4, entonces se necesitarán únicamente tres curvas. La longitud del resonador 1 se corresponde con el parámetro $xcav1$, la del resonador 2 con $xcav2$ y la del resonador 3 con $xcav3$. A continuación se muestran las curvas de caracterización de los resonadores 1, 2 y 3. Son diferentes puesto que las aperturas de los iris no son iguales.




Fig. 5-12: Curva de caracterización de la frecuencia de resonancia 1 .




Fig. 5-13: Curva de caracterización de la frecuencia de resonancia 2 .




Fig. 5-14: Curva de caracterización de la frecuencia de resonancia 3 .

Acoplos entre cavidades. Sólo existe acoplo entre cavidades adyacentes a través de irises, no existiendo acoplos cruzados. Para obtener las curvas de caracterización se parte del modelo HFSS siguiente en el cual aparecen dos cavidades separadas por un iris. Se realiza un barrido paramétrico de la apertura del mismo. Se muestra a continuación la estructura a simular y la curva de acoplo obtenida.




Fig. 5-15: Estructura para obtener el acoplo entre cavidades.




Fig. 5-16: Curva de acoplo entre cavidades .

Acoplo de entrada y salida. Para caracterizar el acoplo de entrada se dibuja el modelo con la guía de entrada y el primer iris. El parámetro a variar es la apertura del primer iris y del último, es decir, del iris que se encuentra entre la entrada y el primer resonador, y del que se

encuentra entre el último resonador y la salida. Puesto que la apertura del primer iris y la longitud del primer resonador son iguales a los del último iris y resonador, sólo se necesita una curva. Las gráficas siguientes muestran la estructura a simular y la curva obtenida.




Fig. 5-17: Estructura para obtener el acoplo de entrada.




Fig. 5-18: Curva de acoplo para la cavidad de entrada .

5.4.4 Asociación de parámetros

Una vez que se han obtenido las curvas de caracterización es necesario asociar los parámetros del modelo grueso con los del modelo fino, es decir, llevar a cabo un mapeado entre los dos espacios. El modelo grueso está definido por la matriz de acoplo M del filtro, mientras que el modelo fino por las variables de diseño (longitud de los resonadores y apertura de los iris). Para esta estructura la asociación queda de la siguiente manera:

	Curva	Variable	Unidades	Factores de acoplo
1	Q_entrada.csv	yv01	mm	E
2	Q_entrada.csv	yv1011	mm	S
3	fres1.csv	xcav1	mm	M1,1
4	fres1.csv	xcav5	mm	M5,5
5	fres2.csv	xcav2	mm	M2,2
6	fres2.csv	xcav4	mm	M4,4
7	fres3.csv	xcav3	mm	M3,3
8	k.csv	yv12	mm	MD1,2
9	k.csv	yv23	mm	MD2,3
10	k.csv	yv34	mm	MD3,4
11	k.csv	yv45	mm	MD4,5

Fig. 5-19: Asociación de parámetros entre el modelo fino y el modelo grueso.

Debido a la topología del filtro, éste sólo tiene acoplos directos, no existiendo ningún acoplo cruzado.

La apertura del iris de entrada y el de salida ($yv01$ e $yv1011$) se asocia con el valor de acoplo de entrada ($M_{0,1}$) y el de salida ($M_{5,6}$).

Las longitudes de los resonadores ($xcav1$, $xcav2$, $xcav3$, $xcav4$ y $xcav5$) se asocian con los autoacoplos, es decir, con los valores de la diagonal de la matriz de acoplo ($M_{1,1}$, $M_{2,2}$, $M_{3,3}$, $M_{4,4}$, $M_{5,5}$).

La apertura de los iris 2 a 4 ($yv12$, $yv23$, $yv34$, $yv45$) se asocian con los acoplos directos, es decir, con los valores de la matriz de acoplo $M_{1,2}$, $M_{2,3}$, $M_{3,4}$, $M_{4,5}$.

5.4.5 Optimización

Comienza el proceso de optimización del filtro. En cada simulación se va modificando el filtro objetivo según la optimización de *Broyden* para encontrar la función que realiza el mapeado entre el modelo fino y el modelo grueso.

En la primera iteración, se lleva a cabo la extracción de parámetros del filtro obtenido en HFSS, obteniéndose la siguiente matriz de acoplo:

	E	1	2	3	4	5	S
E	0	1.332	0	0	0	0	0
1	1.332	-105.604	0.801	-0.030	0.006	-0.003	0
2	0	0.801	-188.568	0.531	-0.045	0.005	0
3	0	-0.030	0.531	247.486	0.530	-0.030	0
4	0	0.006	-0.045	0.530	189.333	0.801	0
5	0	-0.027	0.005	-0.030	0.801	-101.599	1.333
S	0	0	0	0	0	1.333	0

Tabla 5-2: Matriz de acoplo extraída para la primera iteración.

Si la comparamos con la matriz objetivo se puede observar que la respuesta obtenida se aleja bastante de la objetivo. Los valores de los autoacoplos son muy diferentes. Los acoplos directos tampoco son los deseados.

	E	1	2	3	4	5	S
E	0	1.078	0	0	0	0	0
1	1.078	0	0.929	0	0	0	0
2	0	0.929	0	0.663	0	0	0
3	0	0	0.663	0	0.663	0	0
4	0	0	0	0.663	0	0.929	0
5	0	0	0	0	0.929	0	1.078
S	0	0	0	0	0	1.078	0

Tabla 5-3: Matriz de acoplo objetiva.

La respuesta correspondiente a esta primera iteración es:




Fig. 5-20: Respuesta de parámetros S de la primera extracción y del filtro objetivo.

Iteración 2:

Puesto que no cumple las especificaciones se lleva a cabo una reoptimización del modelo grueso utilizando la actualización de *Broyden*. Para ello se tiene en cuenta la matriz M objetivo (Tabla 5-3) y la matriz M obtenida en la extracción (Tabla 5-2). Con la información de ambas se calcula una nueva matriz M que se convierte a parámetros físicos gracias a las curvas de caracterización. Posteriormente, se realiza una simulación en el modelo fino de dichos parámetros y se obtiene la siguiente respuesta:




Fig. 5-21: Respuesta de parámetros S de la segunda extracción y del filtro objetivo.

Iteración 3:




Fig. 5-22: Respuesta de parámetros S de la tercera extracción y del filtro objetivo.

Iteración 4:




Fig. 5-23: Respuesta de parámetros S de la cuarta extracción y del filtro objetivo.

Iteración 5:




Fig. 5-24: Respuesta de parámetros S de la quinta extracción y del filtro objetivo.

Iteración 6:




Fig. 5-25: Respuesta de parámetros S de la sexta extracción y del filtro objetivo.

Iteración 7:




Fig. 5-26: Respuesta de parámetros S de la séptima extracción y del filtro objetivo.

Iteración 17:




Fig. 5-27: Respuesta de parámetros S de la última extracción y del filtro objetivo.

Se puede observar cómo tras 17 iteraciones el filtro se asemeja al filtro objetivo. La matriz de acoplo obtenida para este caso es la siguiente:

	E	1	2	3	4	5	S
E	0	1.078	0	0	0	0	0
1	1.078	-1.038	0.929	-0.049	0.010	-0.01	0
2	0	0.929	-2.331	0.663	-0.069	0.010	0
3	0	-0.049	0.663	-3.246	0.663	-0.049	0
4	0	0.010	-0.069	0.662	-1.859	0.928	0
5	0	-0.001	0.010	-0.049	0.928	3.703	1.078
S	0	0	0	0	0	1.078	0

Tabla 5-4: Matriz de acoplo en la última iteración.

Comparándola con la del objetivo:

	E	1	2	3	4	5	S
E	0	1.078	0	0	0	0	0
1	1.078	0	0.929	0	0	0	0
2	0	0.929	0	0.663	0	0	0
3	0	0	0.663	0	0.663	0	0
4	0	0	0	0.663	0	0.929	0
5	0	0	0	0	0.929	0	1.078
S	0	0	0	0	0	1.078	0

Tabla 5-5: Matriz M objetivo.

Se puede observar como los acoplos directos son iguales en ambas matrices. Aparecen en cambio acoplos parásitos debido a que el filtro no es ideal.

En cuanto a los autoacoplos, el valor de desviación en frecuencia es bastante pequeño, de en torno a un 0.02% $((3.7/18000)*100)$.

Se ha conseguido por tanto optimizar un filtro sólo con 17 simulaciones en HFSS. Esto supone una reducción muy clara del tiempo de simulación en comparación con el optimizador que existe en HFSS o CST.

5.5 Ejemplo 2: Optimización de filtro de cavidades de orden 5

A continuación se va a probar el algoritmo obtenido en un filtro de cavidades acopladas de orden 5. Se trata de un filtro cuya frecuencia central es 2 GHz y ancho de banda 39.2 MHz.

5.5.1 Filtro objetivo

La respuesta objetivo que se busca conseguir es la siguiente:




Fig. 5-28: Respuesta objetivo para el filtro de cavidades.

5.5.2 Diseño HFSS

La estructura del filtro de cavidades se muestra a continuación. Se trata de un filtro con 5 cavidades resonantes en las que el acoplo se realiza mediante ventanas. Dicho acoplo varía según la altura que tenga la ventana. La alimentación se lleva a cabo a través de una sonda coaxial y la frecuencia de resonancia en cada resonador depende de la profundidad que tenga el tornillo de ajuste correspondiente.




Fig. 5-29: Estructura del filtro de cavidades en HFSS.

Cada cavidad está formada por un cilindro de teflón en el cual está insertado un cilindro de metal. Dentro de este cilindro de metal existe otro cilindro de teflón mucho más pequeño. Las partes metálicas de la estructura se muestran a continuación:




Fig. 5-30: Partes metálicas de la estructura.

Las siguientes figuras muestran las partes de teflón existentes en el filtro:




Fig. 5-31: Partes de teflón en la estructura (I).




Fig. 5-32: Partes de teflón en la estructura (II).

Se busca encontrar los valores de la altura de las ventanas de acoplo, la profundidad de los tornillos de ajuste y la altura de la sonda de entrada que permiten obtener la respuesta objetivo.

La respuesta inicial de esta estructura es la siguiente:




Fig. 5-33: Respuesta inicial del filtro de cavidades.

5.5.3 Obtención de las curvas de caracterización

Como ya se ha comentado anteriormente, para llevar a cabo el mapeado entre el modelo fino y el modelo grueso es necesario obtener las curvas de caracterización de la estructura:

- Curvas de frecuencia de resonancia de los resonadores
- Curvas de acoplo entre cavidades
- Curvas de acoplo entrada/salida

Curvas de frecuencia de resonancia. La variación de la frecuencia de resonancia de la cavidad se realiza mediante un tornillo de ajuste.




Fig. 5-34: Ubicación del tornillo de ajuste en la cavidad.

Para obtener la curva de caracterización se realiza por tanto un barrido de la profundidad que alcanza el tornillo en la cavidad. La simulación utilizada es *EigenMode*. Puesto que los resonadores 1 y 5 y 2 y 4 son iguales, se obtienen tres curvas, las cuales se muestran a continuación:




Fig. 5-35: Curva de caracterización del primer resonador.




Fig. 5-36: Curva de caracterización del segundo resonador.




Fig. 5-37: Curva de caracterización del tercer resonador.

Acoplo entre cavidades. En esta estructura sólo hay acoplos directos, los cuales se llevan a cabo a través de ventanas. No existen acoplos cruzados. Para obtener esta curva se lleva a cabo un barrido de la altura de la ventana.




Fig. 5-38: Ubicación de la altura de la ventana.

Se realizan simulaciones de tipo *EigenMode*. Así, a mayor altura, mayor acoplo, puesto que la ventana es de mayor tamaño. La curva obtenida es la siguiente:




Fig. 5-39: Curva de caracterización del acoplo entre cavidades.

Acoplos de entrada/salida. La alimentación de este filtro se realiza mediante una sonda coaxial tal y como se muestra en la siguiente figura:




Fig. 5-40: Estructura para la caracterización del acoplo de entrada.

La caracterización del acoplo de entrada consistirá en un barrido paramétrico de la altura a la que se coloca la sonda. La curva que se obtiene es la siguiente:




Fig. 5-41: Curva de caracterización del acoplo de entrada.

5.5.4 Asociación de parámetros

A continuación se lleva a cabo la asociación de parámetros entre el modelo fino (variables de diseño de la estructura) y el modelo grueso (matriz de acoplo). La asociación es la siguiente:

	Curva	Variable	Unidades	Factores de acoplo
1	Qext.csv	hioE	mm	E
2	Qext.csv	hioS	mm	S
3	fres1.csv	ts1p	mm	M1,1
4	fres1.csv	ts5p	mm	M5,5
5	fres2.csv	ts2p	mm	M2,2
6	fres2.csv	ts4p	mm	M4,4
7	fres3.csv	ts3p	mm	M3,3
8	k_ts2.csv	v12h	mm	MD1,2
9	k_ts2.csv	v23h	mm	MD2,3
10	k_ts2.csv	v34h	mm	MD3,4
11	k_ts2.csv	v45h	mm	MD4,5

Tabla 5-6: Asociación de parámetros entre el modelo fino y el grueso.

La altura a la que se coloca la sonda coaxial en la cavidad inicial y final se corresponde con el acoplo de entrada y de salida ($M_{0,1}$, $M_{5,6}$).

En cuanto a los acoplos directos ($M_{1,2}$, $M_{2,3}$, $M_{3,4}$ y $M_{4,5}$), estos se relacionan con la altura que tienen las ventanas de acoplo.

La profundidad de los tornillos de ajuste se asocia con los autoacoplos ($M_{1,1}$, $M_{2,2}$, $M_{3,3}$, $M_{4,4}$, $M_{5,5}$).

5.5.5 Optimización

Se procede a optimizar la estructura mediante el algoritmo programado. A continuación se va a mostrar la respuesta del filtro extraído para cada iteración:

Extracción inicial:




Fig. 5-42: Respuesta inicial extraída.

Iteración 1:

Se lleva a cabo una reoptimización del modelo grueso mediante la actualización *Broyden*, la cual utiliza la información de la matriz de acoplo objetivo y de la matriz M obtenida a partir de la respuesta de parámetros S del modelo fino. La nueva respuesta se muestra a continuación:




Fig. 5-43: Respuesta de parámetros S de la primera iteración y del filtro objetivo.

Iteración 2:




Fig. 5-44: Respuesta de parámetros S de la iteración 2 y del filtro objetivo.

Iteración 3:




Fig. 5-45: Respuesta de parámetros S de la iteración 3 y del filtro objetivo.

Iteración 4:




Fig. 5-46: Respuesta de parámetros S de la iteración 4 y del filtro objetivo.

Iteración 5:




Fig. 5-47: Respuesta de parámetros S de la iteración 5 y del filtro objetivo.

Iteración 6:




Fig. 5-48: Respuesta de parámetros S de la iteración 6 y del filtro objetivo.

Iteración 7:




Fig. 5-49: Respuesta de parámetros S de la iteración 7 y del filtro objetivo.

Tras 7 iteraciones del algoritmo se logra obtener la respuesta del filtro objetivo. Se puede observar como la respuesta objetivo y la obtenida son idénticas.

5.6 Conclusiones

Tras los ejemplos expuestos anteriormente se puede observar cómo la técnica de *mapeado espacial* ha permitido mejorar el tiempo de optimización de dos filtros de topologías diferentes, reduciendo el número de ejecuciones necesarias en el simulador electromagnético (HFSS en este caso). Además, los resultados obtenidos cumplen los objetivos de diseño iniciales. La técnica utilizada ha sido *agresive space mapping*, pero existen numerosos tipos los cuales podrían igualar o incluso mejorar los resultados obtenidos.

Esta técnica está siendo utilizada en la industria espacial. Concretamente en *Thales Alenia Space España*, donde se ha realizado parte de este trabajo. En dicha empresa se utiliza *space mapping* para diseñar filtros para satélites de comunicaciones. Allí se cuenta con una interfaz de usuario que permite optimizar diseños de filtros que inicialmente no cumplen las especificaciones deseadas. Esto se realiza en un tiempo mucho menor al que se emplearía utilizando los optimizadores de las herramientas comerciales.

6 Conclusiones y trabajo futuro

6.1 Conclusiones

En este proyecto se han buscado técnicas que permitan reducir el tiempo necesario para llevar a cabo el cálculo de la respuesta de parámetros S de diferentes estructuras de microondas como filtros y acopladores. La simulación electromagnética de estas estructuras es lenta por lo que para llevar a cabo una optimización que involucre a su vez numerosas evaluaciones de las prestaciones de una estructura da lugar a que el tiempo empleado sea muy elevado.

La primera parte se ha centrado en las redes neuronales. Se ha utilizado el *toolbox* de *Matlab* para construir las redes y llevar a cabo su entrenamiento y simulación. Se han creado redes neuronales en este entorno y se ha comprobado su funcionamiento comparándolo con el de otras redes ya creadas. El primero paso ha sido obtener los datos de entrenamiento que permiten poner en funcionamiento la red. Para ello se ha utilizado CST y *Matlab*, y se han generado los datos de entrada (variables de diseño del filtro) y los de salida (respuesta de parámetros S). Con estos datos, se pasa a entrenar la red.

Como primer objetivo se han entrenado redes que simulan el comportamiento de un filtro en guía de onda de orden 3. No obstante, la red no ha sido capaz de aprender el comportamiento y presenta una respuesta que no coincide con la deseada. Se ha optado entonces por crear redes neuronales que simulen únicamente el comportamiento de un único iris y no del filtro completo. En este caso la red neuronal sí es capaz de aprender el comportamiento pero sólo en el caso de que la frecuencia forme parte de la entrada de la red.

Posteriormente, se ha llevado a cabo el mismo proceso utilizando acopladores en guía de onda de tipo *branch* de tres ramas. Los resultados obtenidos indican que la red es capaz de simular el comportamiento, aunque existe un ruido que aumenta conforme aumenta el número de puntos de frecuencia. Al incluir la frecuencia como parámetro de la red neuronal, los resultados mejoran.

La segunda parte del proyecto ha consistido en el estudio y desarrollo de técnicas de mapeado espacial que permitan reducir el tiempo de simulación. Éstas logran dicha reducción gracias al uso de dos modelos, uno más rápido que otro, tratando de disminuir el número de simulaciones del modelo más lento. Se ha implementado el algoritmo de *aggressive space mapping* y se ha probado con un filtro en guía de onda de iris y otro de cavidades, ambos de orden 5. En los dos casos se ha conseguido reducir el número de simulaciones en el simulador electromagnético lento, y por consiguiente, reducir el tiempo de simulación global.

Estas técnicas de mapeado espacial se usan ya en la industria. Un ejemplo de ello es *Thales Alenia Space España*, empresa del sector espacial en la cual el diseño de filtros utiliza dicha tecnología para reducir el tiempo de simulación y por tanto del coste.

En este proyecto se han presentado técnicas muy diversas que tienen como objetivo común reducir el tiempo de simulación y el coste asociado al diseño de dispositivos de microondas. Para ello ha sido necesario utilizar software comercial de diferente tipo: *Matlab*, HFSS y CST, así como familiarizarse con dispositivos tales como filtros y acopladores.

Debido a esta diversidad, este trabajo ha supuesto un reto pues ha implicado el estudio de diferentes componentes, diferentes tecnologías así como diferente software.

6.2 Trabajo futuro

Como trabajo más inmediato se propone utilizar otras técnicas de mapeado espacial de manera que se intente mejorar con ellas el tiempo de simulación logrado con *aggressive space mapping*.

Como trabajo futuro se propone probar las técnicas de *space mapping* a otro tipo de filtros, así como a filtros más complejos y de mayor orden.

Otra posibilidad sería ampliar las técnicas de mapeado espacial a la optimización de otros dispositivos como acopladores.

En cuanto a las redes neuronales, se propone mejorar las redes que se han utilizado buscando configuraciones y estructuras que puedan ofrecer mejores resultados.

Otra objetivo sería utilizarlas en otro tipo de componentes de microondas para comprobar si son capaces de reproducir su comportamiento y reducir así los tiempos de simulación.

Referencias

- [1] **D. M. Pozar**, Microwave Engineering, John Wiley & Sons, Inc, 2005.
- [2] **R. E. Collin**, Foundations for Microwave Engineering, IEEE Press, 2001.
- [3] **R. J. Cameron, C. M. Kudsia and R. R. Mansour**, Microwave filters for communication systems fundamentals, design and applications, Wiley-Interscience, 2007.
- [4] **S. Haykin**, Neural Networks: A Comprehensive Foundation, Prentice Hall, 1994.
- [5] **Qi-Jun Zhang; Gupta, K.C.; Devabhaktuni, V.K.**, "Artificial neural networks for RF and microwave design - from theory to practice," *Microwave Theory and Techniques, IEEE Transactions on* , vol.51, no.4, pp.1339,1350, Apr 2003
doi: 10.1109/TMTT.2003.809179
- [6] **K. Hornik, M. Stinchcombe, and H. White**, "Multilayer feedforward networks are universal approximators," *Neural Networks*, vol. 2, pp. 359-366, 1989.
- [7] **Bandler, J.W.; Cheng, Q.S.; Dakroury, S.A.; Mohamed, A.S.; Bakr, M.H.; Madsen, K.; Sondergaard, J.**, "Space mapping: the state of the art," *Microwave Theory and Techniques, IEEE Transactions on* , vol.52, no.1, pp.337,361, Jan. 2004
doi: 10.1109/TMTT.2003.820904
- [8] **Bakr, M.H.; Bandler, J.W.; Biernacki, R.; Shao Hua Chen; Madsen, K.**, "A trust region aggressive space mapping algorithm for EM optimization," *Microwave Theory and Techniques, IEEE Transactions on* , vol.46, no.12, pp.2412,2425, Dec 1998
doi: 10.1109/22.739229
- [9] **Bandler, J.W.; Cheng, Qingsha S.; Hailu, D.M.; Nikolova, N.K.**, "A space-mapping design framework," *Microwave Theory and Techniques, IEEE Transactions on* , vol.52, no.11, pp.2601,2610, Nov. 2004
doi: 10.1109/TMTT.2004.837201
- [10] **Morro, J.V.; Esteban, H.; Boria, V.E.; Bachiller, C.; Coves, A.**, "New multimodel aggressive space mapping technique for the efficient design of complex microwave circuits," *Microwave Symposium Digest, 2005 IEEE MTT-S International* , vol., no., pp.4 pp., 12-17 June 2005
doi: 10.1109/MWSYM.2005.1517013
- [11] **Bakr, M.H.; Bandler, J.W.; Georgieva, N.; Madsen, K.**, "A hybrid aggressive space-mapping algorithm for EM optimization," *Microwave Theory and Techniques, IEEE Transactions on* , vol.47, no.12, pp.2440,2449, Dec 1999
doi: 10.1109/22.808991

